

Česká zemědělská univerzita v Praze

Fakulta lesnická a dřevařská

Katedra lesnické genetiky a fyziologie



Česká
zemědělská
univerzita
v Praze

**Hodnocení obrazových dat u juvenilních stádií
borovice lesní**

Diplomová práce

Autor: Bc. Jiří Chuchlík

Vedoucí práce: RNDr. Jaroslav Čepl, Ph.D.

2024

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta lesnická a dřevařská

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Jiří Chuchlík

Lesní inženýrství

Název práce

Hodnocení obrazových dat u juvenilních stadií borovice lesní

Název anglicky

Evaluation of image data in juvenile stages of Scots pine

Cíle práce

Cílem práce je testování přítomnosti genetické variability dat získaných pomocí high-throughput fenotypovacích přístupů.

Dalšími cíli jsou segmentace obrazových dat u časných testů potomstev borovice lesní s akcentem na fenologii a zjištění korelace mezi hyperspektrálními daty a daty získanými segmentací z RGB snímků.

Tato evaluace umožní ověřit hypotézu o genetické podmíněnosti sledovaných znaků na úrovni ekotypů či rodin.

Metodika

Práce bude probíhat na RGB snímcích tři zájmových populací borovice lesní – Plzeňské, Třeboňské a Děčínské.

Stanovení variability obrazových dat vyžaduje jejich podrobnou segmentaci. Obzvláště u jehličnatých dřevin je segmentace pixelů jednotlivých rostlin extrémně náročná. Metodicky vhodné je využití algoritmů umělé inteligence. Tyto metody vyžadují relativně vysoký počet vzorků, v našem experimentu disponujeme řádově tisíci sazenicemi.

Harmonogram:

Statistické vyhodnocení získaných dat proběhne během ledna a února 2024 s využitím smíšených lineárních modelů (software ASReml).

Literární rešerše a metodika práce budou odevzdány do konce února 2024. Výsledky a diskuze bude dokončena do 15. března 2024.

Doporučený rozsah práce

70-80 stran + přílohy

Klíčová slova

Obrazová data, borovice lesní, fenotypování, strojové učení, genetická variabilita

Doporučené zdroje informací

- Albrechtová, J., Kupková, L., & Campbell, P. K. (2017). Metody hodnocení fyziologického stavu smrkových porostů: případové studie sledování vývoje stavu smrkových porostů v Krušných horách v letech 1998-2013. Česká geografická společnost.
- Butler, D. G., Cullis, B. R., Gilmour, A. R., Gogel, B. J., & Thompson, R. (2017). ASReml-R reference manual version 4. VSN International Ltd, Hemel Hempstead, HP1 1ES, UK.
- Cavender-Bares, J., Meireles, J. E., Couture, J. J., Kaproth, M. A., Kingdon, C. C., Singh, A., ... & Townsend, P. A. (2016). Associations of leaf spectra with genetic and phylogenetic variation in oaks: prospects for remote detection of biodiversity. *Remote Sensing*, 8(3), 221.
- Redmon, J.; Divvala, S.; Girshick, R. a Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. ArXiv [online]. [cit. 2024-02-28]
- Rincent, R., Charpentier, J. P., Faivre-Rampant, P., Paux, E., Le Gouis, J., Bastien, C., & Segura, V. (2018). Phenomic selection is a low-cost and high-throughput method based on indirect predictions: proof of concept on wheat and poplar. *G3: Genes, Genomes, Genetics*, 8(12), 3961-3972
- Stejskal, J.; Čepl, J.; Neuwirthová, E.; Akinyemi, O., O.; Chuchlík, J. et al. (2023). Making the Genotypic Variation Visible: Hyperspectral Phenotyping in Scots Pine Seedlings. *Plant Phenomics* [online], vol. 5
- Taiz, L.; Zeigler, E. (2002). *Plant Physiology*. 3rd ed. Sunderland: Sinauer Associates, ISBN 087893823
- Tomášková, I.; Kubásek, J. *Fyziologie lesních dřevin I.: fyziologie, produkce a stresy rostlin*. Praha: Česká zemědělská univerzita v Praze, Fakulta lesnická a dřevařská, katedra genetiky a fyziologie lesních dřevin, 2016. 267 p. ISBN 978-80-213-2608-8.
-

Předběžný termín obhajoby

2023/24 LS – FLD

Vedoucí práce

RNDr. Jaroslav Čepl, Ph.D.

Garantující pracoviště

Katedra lesnické genetiky a fyziologie

Elektronicky schváleno dne 10. 3. 2024

doc. Ing. Ivana Tomášková, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 10. 3. 2024

prof. Ing. Róbert Marušák, PhD.

Děkan

V Praze dne 13. 03. 2024

Prohlášení

Prohlašuji, že jsem diplomovou práci na téma: Hodnocení obrazových dat u juvenilních stadií borovice lesní vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil, a které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

Jsem si vědom, že na moji diplomovou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů, ve znění pozdějších předpisů, především ustanovení § 35 odst. 3 tohoto zákona, tj. o užití tohoto díla.

Jsem si vědom, že odevzdáním diplomové práce souhlasím s jejím zveřejněním podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby.

Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

V Praze dne 4. 4. 2024

Jiří Chuchlík

Poděkování

Na tomto místě bych rád poděkoval zejména vedoucímu mé bakalářské práce RNDr. Jaroslavu Čeplovi, PhD. za pomoc se zpracováním dat, ochotu, vstřícnost, vynaložený čas, odborné rady a odborné vedení. Dále bych rád poděkoval mým přátelům, kteří mi pomáhali se sběrem dat a kontrolou práce. V neposlední řadě patří dík mé rodině za podporu a trpělivost po celou dobu mého studia.

Hodnocení obrazových dat u juvenilních stadií borovice lesní

Abstrakt

Klimatická změna ovlivňuje vitalitu současných lesů a je nutné na tyto změny reagovat. Možností je změna druhové skladby, využití exotických druhů nebo využití odolnějších jedinců domácích dřevin. Borovice lesní, jako druhá nejvýznamnější dřevina v České republice, má vysoký adaptační potenciál díky dosud nevyužité genetické variabilitě na úrovni ekotypů a lokálních populací. Pro šlechtitelské programy je v současné době dostupné množství genotypizačních metod, které, ačkoliv se zlevňují, jsou často pro lesnické subjekty stále nedostupné. Alternativou mohou být metody fenotypizace adaptačních znaků. Měření spektrálních parametrů je rychlou a levnou možností, nicméně stále vyžaduje specializované přístroje. Doplnění či částečné nahrazení obrazovými daty pořízenými komerčně dostupnými fotoaparáty může zlevnit a zjednodušit získávání potřebných informací. Práce probíhala na snímcích semenáčků 3 zájmových populací borovice lesní. Segmentační algoritmus YOLOv7 se ukázal jako účinný nástroj pro segmentaci jehličnatých semenáčků. Výsledky ukazují fenologické rozdíly mezi zkoumanými obdobími i populacemi. Korelace segmentované barvy a barvy získané kolorimetrickými funkcemi nejsou vysoké vzhledem k vnějším vlivům. Populace vykazují nízkou, přesto signifikantní heritabilitu v různých parametrech barevných systémů, a zároveň se statisticky významně liší. Tyto metody naznačují využitelnost barevné informace jehličnatých semenáčků ve šlechtění lesních dřevin.

Klíčová slova: obrazová data, borovice lesní, fenotypování, strojové učení, genetická variabilita

Evaluation of image data in juvenile stages of Scots pine

Abstract

Climate change affects the vitality of present-day forests, and it is necessary to respond to these changes. Options include changing the species composition, using exotic species or using more resistant individuals of native trees. Scots pine, as the second most important tree species in the Czech Republic, has a high adaptation potential due to as yet untapped genetic variability at the level of ecotypes and local populations. A number of genotyping methods are currently available for breeding programs, which, although becoming cheaper, are often still unavailable to forestry entities. An alternative may be methods of phenotyping adaptation traits. Measuring spectral parameters is a quick and cheap option, but still requires specialized equipment. Supplementing or partially replacing it with image data taken by commercially available cameras can make it cheaper and easier to get the necessary information. The work was carried out on images of seedlings of 3 pine populations of interest. The YOLOv7 segmentation algorithm proved to be an effective tool for conifer seedling segmentation. The results show phenological differences between the studied periods and populations. The correlation of segmented color and color obtained by colorimetric functions is not high due to external influences. Populations show low, yet significant heritability in various parameters of color systems, and at the same time they are statistically significantly different. These methods indicate the usefulness of the color information of conifer seedlings in the breeding of forest trees.

Keywords: image data, Scots pine, phenotyping, machine learning, genetic variability

Obsah

1. Úvod	14
2. Cíl práce.....	15
3. Literární rešerše	16
3.1. Borovice lesní	16
3.1.1. Systematické zařazení	16
3.1.2. Biologie a ekologie	16
3.1.3. Areál rozšíření.....	18
3.1.4. Provenience a ekotypy borovice lesní	19
3.1.5. Hospodářský význam.....	20
3.2. Šlechtění lesních dřevin	21
3.2.1. Cíle šlechtění lesních dřevin	21
3.2.2. Princip šlechtění lesních dřevin	22
3.2.3. Semenné sady	24
3.2.4. Fyziologie lesních dřevin ve šlechtění	26
3.3. Fenologie	26
3.3.1. Fenologie borovice lesní	27
3.4. Rostlinné pigmenty	27
3.4.1. Chlorofyly	28
3.4.2. Karotenoidy	29
3.4.3. Antokyany.....	30
3.5. Spektroskopie a spektrometrie.....	30
3.5.1. Elektromagnetické záření	31
3.5.2. Interakce energie a hmoty.....	32
3.5.3. Křivka spektrální odrazivosti.....	33
3.5.4. Spektrální rozlišení	34
3.5.5. Spektroradiometr	35

3.5.6.	Spektrální reflektance vegetace	35
3.5.7.	Spektrální reflektance a heritabilita	38
3.6.	Kolorimetrie	40
3.6.1.	Barevné systémy	40
3.6.2.	Výpočet hodnot barev pomocí kolorimetrických funkcí	41
3.6.3.	Systém RGB	42
3.6.4.	Systém HSV	43
3.6.5.	RGB a barva listu	45
3.6.6.	RGB a heritabilita	46
3.7.	Segmentace	47
3.7.1.	Algoritmus YOLO („You Only Look Once“)	47
3.7.2.	Detekce objektů pomocí YOLO	48
3.7.3.	Segmentace objektů pomocí YOLO	49
3.7.4.	Trénování segmentačního modelu na vlastních datech	50
4.	Metodika	52
4.1.	Původ reprodukčního materiálu	52
4.2.	Podmínky pěstování semenáčků	53
4.3.	Terénní měření	54
4.3.1.	Měření spektroradiometrem s optickým kabelem	54
4.3.2.	Pořízení fotografií	55
4.4.	Získání RGB dat z fotografií.	55
4.4.1.	Standardizace dat pomocí bílé reference	55
4.4.2.	Transformace obrázku	56
4.4.3.	Rozřezání obrázku	56
4.4.4.	Vytvoření segmentačního modelu	57
4.4.5.	Segmentace pomocí YOLOv7	57
4.4.6.	Odstranění pozadí segmentovaných jehlic	58

4.4.7.	Spojení částí do celého obrázku.....	58
4.4.8.	Překryv jednotlivých výstupů	59
4.4.9.	Identifikace jednotlivých stromků a získání RGB hodnot.....	60
4.5.	Genomická data	61
4.6.	Výpočet RGB a HSV hodnot ze spektrální křivky	61
4.7.	Statistická analýza dat.....	62
4.7.1.	Církulární data	62
4.7.2.	Analýza hlavních komponent – PCA.....	62
4.7.3.	Korelační koeficient.....	63
4.7.4.	Částečná regrese nejmenších čtverců – PLSR.....	63
4.7.5.	Smíšené lineární modely	64
5.	Výsledky	65
5.1.	Segmentace semenáčků borovic	65
5.2.	Fenologie – změna barvy v různých obdobích	66
5.2.1.	Fenologie – změna parametrů systému HSV v různých obdobích.....	66
5.2.2.	Fenologie – změna parametrů systému RGB v různých obdobích.....	68
5.3.	Korelace barev získaných segmentací a barev získaných z hyperspektrálních dat	68
5.3.1.	Korelace barev ze segmentace a barev vypočtených z hyperspektrálních dat pomocí kolorimetrických funkcí	68
5.3.2.	Korelace barev ze segmentace a barev predikovaných z hyperspektrálních dat pomocí modelů PLSR.....	69
5.4.	Porovnání populací	70
5.4.1.	Porovnání populací na základě HSV	70
5.4.2.	Porovnání populací na základě RGB	71
6.	Diskuze	73
6.1.	Segmentace semenáčků borovic	73
6.2.	Fenologie – změna barvy v různých obdobích	74

6.2.1. Fenologie – změna parametrů systému HSV v různých obdobích	74
6.2.2. Fenologie – změna parametrů systému RGB v různých obdobích.....	75
6.3. Korelace barev získaných segmentací a barev získaných z hyperspektrálních dat	76
6.3.1. Korelace barev ze segmentace a barev vypočtených z hyperspektrálních dat pomocí kolorimetrických funkcí	76
6.3.2. Korelace barev ze segmentace a barev predikovaných z hyperspektrálních dat pomocí modelů PLSR.....	77
6.4. Porovnání populací	77
6.4.1. Porovnání populací na základě HSV	77
6.4.2. Porovnání populací na základě RGB	78
7. Závěr.....	80
8. Seznam použité literatury	81
9. Seznam obrázků.....	91
10. Seznam tabulek.....	92
11. Seznam rovnic	93
12. Přílohy	94

Seznam použitých zkratk a symbolů

CIE = Mezinárodní komise pro osvětlování („*Commission Internationale de l'Eclairage*“).

DNA = Deoxyribonukleová kyselina

ČHMÚ = Český hydrometeorologický ústav.

GPS = Globální polohový systém („*Global positioning System*“).

h^2 = Heritabilita / dědivost v úzkém smyslu.

K = Kelvin, jednotka termodynamické teploty.

SI = Mezinárodní soustava jednotek („*Système International d'Unités*“).

HSV = Barevný systém používající k identifikaci barvy parametry odstín, sytost a hodnotu jasu („*Hue, Saturation, Value*“).

IoU = Podíl průniku a sjednocení ohraničujícího boxu a objektu při detekci („*Intersection over Union*“).

LR test = Likelihood-ratio test, statistický test ověřující shodu dvou konkurenčních statistických modelů.

LS = Lesní správa.

LSD = Nejmenší významný rozdíl („*Least Significant Difference*“), statistický test pro mnohonásobné porovnávání.

LVS = Lesní vegetační stupeň.

NIR = Blízké infračervené záření („*Near Infrared Radiation*“).

nm = Nanometr.

ONA = Algoritmus řešící optimální prostorové rozložení ramet v semenných sadech („*Optimum Neighborhood Algorithm*“).

PCA = Analýza hlavních komponent („*Principal Component Analysis*“).

PLO = Přírodní lesní oblast.

REIP = Inflexní bod červeného okraje („*Red-Edge Inflexion Point*“).

REML = Metoda maximální věrohodnosti („*Residual Maximum Likelihood*“).

RGB = Barevný systém používající poměr červené, zelené a modré („*Red, Green, Blue*“).

R^2 = Koeficient determinace, míra kvality regresního modelu

SLT = Soubor lesních typů.

SNP = Jednonukleotidový polymorfismus („*Single Nucleotid Polymorphism*“), genetický marker.

SWIR = Krátkovlnné infračervené záření („*Shortwave Infrared Radiation*“).

VIP skóre = Význam proměnných v projekci („*variable importance in the projection*“), měřítko důležitosti proměnné v modelu PLSR.

VIS = Viditelná část elektromagnetického spektra záření („*visible spectrum*“).

VÚLHM = Výzkumný ústav lesního hospodářství a myslivosti.

WGS-84 = Světový geodetický systém 1984 („*World Geodetic System*“).

YOLOv7 = Detekční a segmentační algoritmus („*You Only Look Once version 7*“).

μm = Mikrometr.

PLSR = Částečná regrese nejmenších čtverců („*Partial Least Square Regression*“)

1. Úvod

Současná klimatická změna ovlivňuje frekvenci, trvání a rozsah sucha, což se projeví na budoucím složení lesů. S postupující změnou klimatu se pro zachování hospodářského lesa jeví použitelné dvě základní možnosti: změna druhového složení lesů nebo pěstování odolnějších jedinců. Jelikož má borovice lesní ze všech dřevin největší areál rozšíření, vyskytuje se v celé řadě klimatických podmínek, ve kterých tvoří různé ekotypy. Některé z těchto ekotypů mohou být odolnější a mají tak vyšší potenciál pro využití v zalesňování, nebo přímo ve šlechtitelských programech. Pro založení vyšších semenných sadů se využívá v současné době genotypizace jedinců, jelikož výběr vhodných jedinců na základě fenotypu může být nespolehlivý. Genotypizace šlechtěného materiálu je však velmi nákladný proces. Výběr vhodných jedinců na základě měření optickým kabelem se ukázal jako poměrně levná a rychlá alternativa. Měření reflektance je však stále závislé na specializovaných přístrojích, které nemusí být vždy dostupné. Výběr jedinců na základě obrazových dat pořízených komerčně dostupnými fotoaparáty může vést k významnému usnadnění a zlevnění. Doposud však chyběla účinná metoda pro segmentaci obrazových dat u jehličnatých semenáčků. Taková metoda má předpoklad zjednodušit a automatizovat procesy spojené s nutností využití segmentovaných semenáčků. V rámci této diplomové práce byly měřeny a foceny tři lokální populace z lesních správ Plasy, Třeboň a Děčín. Na tomto unikátním souboru bylo možné efektivně ověřit zmíněné metody.

Měření probíhalo optickým kabelem v roce 2021 v rámci projektu Inter-Action (MŠMT) „Využití genetické variability hyperspektrální odrazivosti ekotypů borovice lesní pro selekci jedinců odolných vůči suchu“. Porovnání metody optického kabelu a kontaktní sondy bylo provedeno v bakalářské práci na téma „Hodnocení hyperspektrální reflektance a růstových parametrů v časném testu potomstev borovice lesní“. Vzhledem k tomu, že tato diplomová práce ze zmíněné práce vychází, jsou některá témata opakována a dále rozvíjena.

2. Cíl práce

Cílem práce je segmentace obrazových dat u časných potomstev borovice lesní s akcentem na fenologii a zjištění korelace mezi hyperspektrálními daty a daty získanými segmentací z RGB snímků. Segmentace je provedena pomocí segmentačního algoritmu YOLOv7, což lze považovat za high-throughput fenotypovací přístup. Součástí práce je též genetická evaluace daného materiálu na základě RGB nebo HSV dat. Tato evaluace umožní ověřit hypotézu o genetické podmíněnosti sledovaných znaků na úrovni ekotypů či populací.

Přínosem práce jsou unikátní poznatky o barevných vlastnostech juvenilního materiálu borovice lesní na pozadí ekotypové proměnlivosti. Dalším přínosem, především pro fyziologickou komunitu, je ověření využitelnosti barevných kanálů jako vhodných ukazatelů fenologie, ale i příslušnosti k určité populaci.

3. Literární rešerše

3.1. Borovice lesní

3.1.1. Systematické zařazení

Borovice lesní (*Pinus sylvestris*, L.) se řadí do superskupiny *Archeplastida*, v rámci které se řadí do říše rostlin – *Plantae* (Zicha 2022). Patří do semenných rostlin, do oddělení nahosemenných (*Pinophyta*). Dále se borovice řadí do třídy jehličnany (*Pinopsida*), podtřídy *Pinidae* a řádu borovicotvaré – *Pinales* (Koblížek 1999). Borovice patří do čeledi borovicovitých (*Pinaceae*). Rod borovice (*Pinus*) je nejpočetnější v této čeledi (Hejný, Slavík 1988). Řád borovicotvarých je největší a zároveň ekologicky i ekonomicky nejvýznamnější skupinou nahosemenných rostlin. Je známý již z období karbonu, z doby asi před 300 miliony let. Čeď borovicovité je pravděpodobně monofyletická skupina. Tomu nasvědčuje mnoho znaků, jako jsou například obrácená vajíčka, proteinový typ plastidů v buňkách sítkovic či absence biflavonoidů v rostlinách (Mártonfi 2006).

3.1.2. Biologie a ekologie

Borovice jsou stálezelené stromy, méně často keře. Jejich borka je typicky popraskaná nebo šupinovitá. Jehlice vyrůstají ve svazečcích, obvykle po 2–5, avšak vzácně mohou být i po jedné nebo ve skupinách 6–8. Svazek je ve spodní části zasazen do blanitých šupinek tvořících tzv. pochvy. Šišky mohou být vejčité, válcovité nebo kulovité. Dozrávají ve druhém nebo třetím roce. Na severní polokouli je známo více než 100 druhů (Hejný, Slavík 1988).

Borovice lesní dosahuje výšky 40 metrů. Kmen je většinou přímý. U starších jedinců je obvyklé, že mají větve až v poslední čtvrtině. Letorosty mají zelenohnědou barvu. Šedozeleň borka borovice lesní je deskovitě rozpukaná. Borka na větvích a v horních částech kmene je však tenká a vytváří rezavě oranžové destičky. (Hejný, Slavík 1988). Strom je poměrně odolný právě díky relativně tlusté borce, jak proti biotickým, tak abiotickým činitelům (Slavík, Bažant 2016).

Borovice lesní vykazuje rozsáhlý kořenový systém s typickým hlavním kořenem, který se obvykle zasahuje do velkých hloubek. Nicméně, v extrémních podmínkách může být tento systém kořenů odlišný. V bažinatých oblastech kořeny nepronikají hluboko, ale

omezují se na tenký povrchový profil půdy. Na skalnatých půdách se kořeny rozkládají po povrchu a vnikají do trhlin. Na písčitéch podložích se mohou u borovic vytvořit chůdovité kořeny v důsledku eroze půdy (Slávik, Bažant 2016).

Dospívající borovice lesní mají pravidelnou korunu ve tvaru kuželu. S rostoucím věkem se koruna stává více kopulovitou, případně deštníkovitou a ubývá na pravidelnosti (Maděra, Úradníček 2001). Nicméně, tvar koruny je závislý také na severojižním gradientu. V oblastech výskytu směrem více na jih převažují zmíněné deštníkovité až klenuté tvary korun. Se vzrůstající zeměpisnou šířkou se ale koruna protahuje a stává se štíhlejší s jemným ovětvením (Musil et al. 2002).

Pupeny borovice lesní mají protáhlý, vejcovitý tvar s ostrou špičkou a jsou převážně pokryty nesmolnatými šupinami. Jehlice vyrůstají ve svazku po dvou a jsou mírně zatočené podél své delší osy. Jejich vnější strana je tmavě zelená a je vyduťatá, tak že průřez jehlicí připomíná písmeno D. Vnitřní strana jehlic je šedozeleň a více zploštělá. Šedozeleň barva je způsobena průduchy, které jsou seřazené v řadách a jsou modravě ožíněné. Okraje jehlic jsou drobně pilovité. Životnost jehlic je přibližně 2–4 roky, poté odumírají a opadávají. Rozměry jehlic jsou poměrně variabilní. Délka se pohybuje od 3,5 do 8,0 cm a šířka jehlic se pohybuje mezi 1,3–1,8 mm (Hejný, Slavík 1988).

Borovice lesní je dřevina s jednodomou reprodukční soustavou, na jednom jedinci se vyskytují květy samčí i samičí. Tyto květy jsou u borovice jednopohlavné. Borovice je anemogamní dřevina, k opylování dochází pomocí větru (Musil et al. 2002). Samčí šištice mají vejčitý tvar a dorůstají 4–8 mm. Jsou bledě žluté a jsou prstencovitě umístěny na letorostech. Samičí šištice jsou výrazně karmínové. Dorůstají 5–6 mm a jsou umístěny po jedné nebo dvou na konci větví. Během podzimu dorůstají do velikosti lískového oříšku. V průběhu dalšího roku dorostou do svých finálních rozměrů. Dozrávají na začátku října v druhém roce a otevírají se obvykle na jaře následujícího roku. Velikost dospělých šišek se různí, v průměru ale dosahují velikosti 70×25 cm. Šupiny mají opatřeny štítky, které mají vždy matnou našedlou barvu. Šišky jsou z vnější strany světle hnědé, vnitřní strana šupin má tmavě hnědou barvu (Slávik, Bažant 2016). Solitérní borovice začínají plodit v 15 letech. V zápoji na suchých půdách plodí po 30 až 40 letech a na mokřích půdách až po 50 letech. Borovice lesní neplodí každoročně, ale obvykle v intervalech 3–4 let. V semenných sadech jsou semenné roky častější (Hejný, Slavík 1988). Borovice lesní se běžně dožívá 300 let, nicméně na exponovaných půdách s nízkou

mírou konkurence se může dožít až 500 let (Slávik, Bažant 2016). Doporučená doba obmýtí se liší v závislosti na přírodních podmínkách, pohybuje se od 80 do 110 let.

Borovice lesní je heliofyt, tedy rostlina nesnášející zastínění. V hustých a zastíněných porostech má problém se zmlazením. Podmínky s volným přístupem světla však zvládá velmi dobře. I přes svoji světlomilnost tvoří souvislé monokulturní porosty. Tyto monokultury však převážně nejsou přirozené, ale jsou tvořeny člověkem nebo vznikají působením požárů (Úradníček, Chmelař 1995). Borovice lesní je dobře adaptovaná na extrémní podmínky. Pomocí svého kořenového systému dokáže získat vodu z velkých hloubek, a proto dokáže růst na extrémně suchých stanovištích. Díky lokálním adaptacím však dokáže růst i na stanovištích s vysokým ovlivněním vodou, jako jsou například rašeliniště. Zvládne růst na velkém množství půd a hornin. Typická jsou stanoviště, nemají ostatní dřeviny tak vysoký potenciál a konkurence je tedy nižší. Může jít například o suché písky nebo vápencové skály. Dokáže růst i na půdách bez obsahu humusu a s minimálním množstvím minerálních látek (Slávik, Bažant, 2016).

3.1.3. Areál rozšíření

Borovice lesní se vyskytuje na největším areálu ze všech dřevin, a zároveň tedy disponuje i největší ekologickou amplitudou. Těžiště výskytu se nachází v severní Asii (Musil et al. 2002). Areál se rozkládá v mírném pásu i chladnějších částech celé Eurasie. V severních oblastech areálu není výjimkou, že borovice zasahuje daleko za polární kruh. V Evropské části se výskyt omezuje na chladnější oblasti a do teplejších nezasahuje. Borovice lesní chybí v nižších polohách a oblastech s oceánským klimatem. V severojižním směru zastoupení klesá a stává se více disjunktním. Naopak v chladnějších oblastech se borovice objevuje především v nížinách. V oblastech s větší frekvencí požárů borovice lesní dominuje nad smrkem. Silná borka a hluboký kořen dávají borovici lepší předpoklady pro přežití. Vzhledem k adaptaci na nižší obsah humusu dokáže borovice oproti smrku lépe zmlazovat na plochách po požáru (Slávik, Bažant 2016). Mapa přirozeného rozšíření borovice lesní je zobrazená na obrázku 1.

Borovice lesní se v České republice vyskytuje na celém území. Přirozený výskyt borovice lesní je zde pouze ostrůvkovitý, ale lidskou činností byla rozšířena i mimo svá přirozená stanoviště. Vznikly tak velké monokultury převážně na písčitých půdách, které jsou známé například z Plzeňska nebo Bzenecka (Úradníček, Chmelař 1995).



Obrázek 1: Mapa přirozeného areálu borovice lesní. 1 – hlavní areál rozšíření; 2 – izolované výskyty; 3 – přírodní populace zaniklé v důsledku lidské činnosti; 4 – polární kruh. Zdroj: Kwiecień (2017).

3.1.4. Provenience a ekotypy borovice lesní

Vzhledem k velikosti svého areálu a ekologické amplitudě je uvnitř druhu borovice lesní extrémní diverzita. Jednotlivé geografické variety se liší ve velikostech stromů, barvě, morfologických, fyziologických nebo růstových projevech (Musil et al. 2002).

Již 18. století vědci zkoumali odlišnost populací borovice lesní. Za zmínku stojí de Vilmorin, který navazuje na výsledky Duhamela a v roce 1820 provádí výsadbu všech dostupných proveniencí borovice lesní. V roce 1862 publikuje výsledky ukazující kontinuální geografickou variaci (White et al. 2007). Na počátku 20. století bylo zřejmé, že se jednotlivé populace borovice lesní významně liší. Na základě experimentů dospěl rakouský vědec Cieslar k závěru, že populace byly dědičně přizpůsobeny délce vegetačního období na jejich stanovišti. Cieslar, ve stejné době jako švýcarský výzkumník Engler, pak dospěl k závěru, že se u smrku ztepilého i borovice lesní vyskytují kontinuální změny od severu k jihu a z vysokých nadmořských výšek do údolí. V roce 1936 švédský vědec Olof Langlet ukázal, že je obsah sušiny v jehlicích během podzimu závislý na zeměpisné šířce. Obsah sušiny odráží stupeň odolnosti a zároveň tím nepřímo dokazuje proměnlivou mrazuvzdornost proveniencí. Koncem 40. let provedl Vilhelms Eiche ve Švédsku provenienční pokusy, kdy na testovacích plantážích sledoval různé provenience ze 100 různých porostů převážně ze Švédska. Na základě tohoto pokusu byly

odvozeny základní znalosti nejen o účincích přenosu sadebního materiálu, ale také o proměnlivosti velkého počtu znaků v rámci každé zkoumané populace. Přenos z jihu na sever zvyšuje úmrtnost, a naopak přenos ze severu na jih zvyšuje šanci na přežití. Z Eichova pokusu vychází i poznatek, že přenos o 1 stupeň zeměpisné šířky způsobí změnu v přežití přibližně o 10 %, zatímco změna o 100 metrů nadmořské výšky způsobí změnu přežití přibližně o 3 % (Eriksson et al. 2006).

Při popisu geografické variability se setkáváme s různými pojmy. Geografická rasa popisuje geneticky podobné jedince, kteří se díky výskytu na určitém území přizpůsobili místním podmínkám pomocí přírodního výběru. Termín ekotyp spojuje rasy s určitými genotypy, které jsou přizpůsobené konkrétnímu stanovišti nebo ekologické nise. Ekotyp je charakterizován více znaky, díky kterým se odlišuje od ostatních ekotypů (White et al. 2007). V České republice se přirozeně vyskytují dva základní ekotypy borovice lesní. Jedná se o chlumní ekotyp, který se vyskytuje v nižších polohách, a o náhorní ekotyp vyšších poloh. Tyto ekotypy se liší zejména v adaptaci na prostředí, vlastnostmi kmene, koruny, a dalšími morfologickými projevy. V lesnické praxi se dále vylišují regionální populace, které mají také své typické vlastnosti. Jedná se například o borovici třeboňskou, která je ceněná zejména kvůli své jakosti dřeva a tvárnosti kmene. Mimo třeboňskou borovici může být dalším příkladem borovice severočeská, západočeská nebo herlatická, vyskytující se v oblasti Nízkého Jeseníku (Máchová et al. 2016).

3.1.5. Hospodářský význam

Borovice lesní je po smrku naší hospodářsky nejvýznamnější dřevinou. Její dřevo je rozdělené na nažloutlou běl a červenohnědé jádro. Dřevo je poměrně lehké, měkké a pružné. Houževnatostí však nedosahuje kvality smrku. Odolnost borovice, jak na vzduchu, tak ve vodě, je vysoká díky vysokému podílu pryskyřice. Vzhledem k mechanickým vlastnostem je podíl zpracování borovice nižší než u smrku. Její dřevo je však dobře využitelné pro výrobu řeziva, pro stavební účely nebo při výrobě rámových konstrukcí panelových dřevostaveb. Dřevo borovice je využíváno i na stavbu srubů nebo k výrobě zahradního nábytku. Dalšími způsoby využití může být výroba překližek, loupaných, ale i krájených dých. Nekvalitní dříví lze použít na výrobu obalových materiálů. Další zpracování je omezené vzhledem k výronům pryskyřice (Slávik, Bažant 2016).

3.2. Šlechtění lesních dřevin

Šlechtění zemědělských plodin a hospodářských zvířat je spojeno s člověkem již od neolitické revoluce. Způsob života začal přecházet k usedlému, zemědělskému a člověk si začal vybírat konkurenceschopnější planě rostoucí rostliny a začal s domestikací zvířat. Lesy nebyly pro člověka zdrojem potravy a jejich zušlechťování začalo tedy až o poznání déle. Jako první jsou zmínky o šlechtění lesů v práci Josefa G. Kölreutera z roku 1765. Zmiňuje hybridy stromů, které dosáhnou plného vzrůstu za polovinu obvyklé doby (Kantor 1975).

Stejně jako u pěstění plodin a chovu zvířat lze dosáhnout genetického zlepšení i se stromy prostřednictvím cíleného a systematického šlechtění. Nicméně kvůli svým charakteristikám přinášejí stromy mnoho výzev. Zaprvé se jedná o dlouhou dobu, než stromy fyziologicky dospějí a vybraní jedinci se mohou křížit. S tím souvisí i problém ve fenologii, kdy stromy jednoho druhu často vykazují rozdíly v době kvetení, což vytváří další problémy v produkci potomstva potřebného pro testování. Další problém je, že testované znaky, jako kvalita dřeva, se projeví až v pokročilém věku. Testování pak trvá roky, nebo i desetiletí, než jsou výsledky spolehlivě určitelné. Další problém spočívá v rozloze areálů jednotlivých druhů dřevin. Vzhledem k velkým areálům existuje mnoho úrovní adaptací na prostředí. Testování pak musí probíhat v rámci celé cílové zóny výsadby, aby se předešlo možné špatné adaptaci (El-Kassaby, Klápště 2016).

3.2.1. Cíle šlechtění lesních dřevin

Cílem šlechtitelských programů je vývoj odrůd, které budou vhodnější pro zalesňování, nebo budou zvyšovat ekonomickou či sociální hodnotu lesa. Zlepšování vlastností je hlavním cílem většiny šlechtitelských programů. Zahrnuje opakované cykly činností, jako je selekce, prolínání selekcí a genetické testování (White et al. 2007). Šlechtění dřevin může mít různé cíle. Mimo výroby kvalitnější suroviny se může jednat o produkci materiálu pro okrasné lesy, nebo pěstování vánočních stromků. Produkty šlechtění mohou být vhodnější pro zalesňování nelesních půd nebo se mohou vyšlechtěné stromy používat pro zamezení eroze půdy. Na základě požadovaného cíle se volí různá selekční kritéria, která jsou použita k vybudování selektovaných populací (Eriksson et al. 2006).

Paule (1992) dělí cíle šlechtění na:

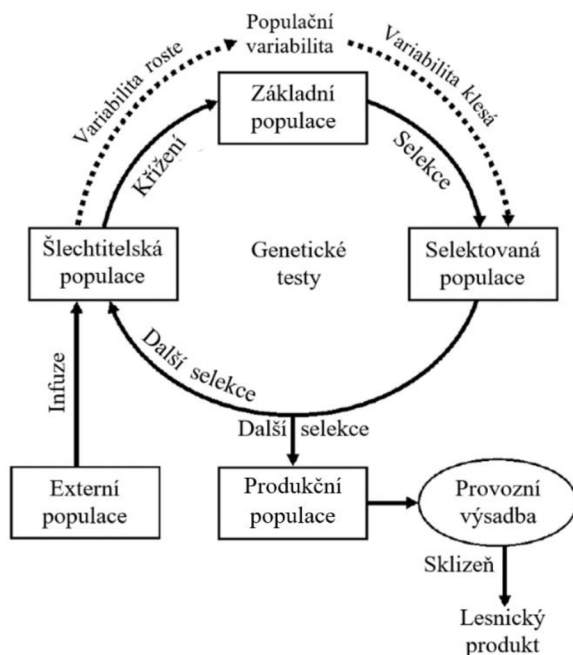
1. Zvýšení kvantity produkce dřevní hmoty nebo dalších produktů (např. pryskyřice)
2. Zvýšení kvality produkce dřevní hmoty nebo dalších produktů
3. Zvýšení odolnosti lesních dřevin
 - a. vůči abiotickým činitelům
 - b. vůči biotickým činitelům

Na prvním místě se obvykle nachází právě zvyšování kvantity produkce. Ta musí jít ruku v ruce se zvýšením kvality. Kvalita je chápána jako přímost, průběh kmene nebo plnodřevnost. Do zvyšování abiotické odolnosti patří například mrazuvzdornost, odolnost vůči suchu, znečištění nebo sněhu. Do biotické odolnosti můžeme zařadit například odolnost vůči ohryzu zvěří, napadení hmyzem nebo houbovými či jinými patogeny (Paule 1992).

3.2.2. Princip šlechtění lesních dřevin

Smyslem šlechtění dřevin je dosáhnout genetického zisku. Ten je definován znaky a vlastnostmi, kterých chce šlechtitelský program dosáhnout. Jestliže jsou tyto znaky definovány, je potřeba odhadnout jejich genetickou variaci a způsob dědičnosti (Eriksson et al. 2006). Heritabilita nám udává, jak velká část proměnlivosti znaku je zapříčiněna genetickými faktory. Vypočte se jako podíl rozptylu fenotypu způsobený genetickými faktory a celkového rozptylu hodnot fenotypu. Pro šlechtění je ale důležitější znalost podílu rozptylu pouze genetické aditivní složky a celkového rozptylu fenotypu. Ten se označuje jako heritabilita v užším smyslu h^2 – „*narrow-sense heritability*“ (White et al. 2007). Aditivní rozptyl je možné použít při hromadném výběru, proto je jeho odhad a odhad aditivního variačního koeficientu důležitý. Při známém aditivním rozptylu je možné vypočítat genetický zisk. Jestliže je neaditivní složka genetického rozptylu vysoká, stává se šlechtění složitějším (Eriksson et al. 2006). Šlechtění lesních dřevin využívá genetickou proměnlivost populací. Hlavním nástrojem šlechtění je selekce. Jestliže jsou vybírány pouze určité stromy, dochází ke zmenšování genetické proměnlivosti. Souběžně se selekcí by měla probíhat opatření, která původní proměnlivost budou udržovat za účelem případných dalších šlechtitelských záměrů (Pospíšil, Koblíha 1988).

Činnosti prováděné v rámci šlechtitelských programů lze shrnout pomocí koncepčního modelu, který se nazývá šlechtitelský cyklus („*the breeding cycle*“). Šlechtitelský cyklus je schematicky zobrazen na obrázku 2. V rámci šlechtitelských programů existují odlišnosti v provádění těchto činností, ve velikosti různých typů populací nebo v intenzitě programů (White et al. 2007).



Obrázek 2: Šlechtitelský cyklus. Zdroj: přeloženo dle White et al. (2007).

Selekce a křížení jsou hlavními činnostmi každého šlechtitelského cyklu. Nejprve jsou selektováni jedinci ze zdrojové populace. Ty poté vytvářejí šlechtitelskou populaci a dochází k vzájemnému křížení, aby se dosáhlo rekombinace alel. Potomstvo získané křížením vytváří produkční populaci dalšího cyklu. Selekcí se z této populace opět vybírají nejlepší jedinci. Jestliže se druhý cyklus provede efektivně, dochází k dalšímu genetickému zisku (White et al. 2007). U semenných sadů vyšší generace nebo dalších cyklů ve šlechtitelských programech zabírá základní populace místo zdrojové populace. Jedinci vybíraní do selektované populace se vybírají z ní. U semenných sadů vyšších generací se již jedinci nevybírají pouze na základě fenotypu (Funda, El-Kassaby 2012). Ve šlechtitelské populaci dochází ke křížení a testování jedinců. Produkční populace slouží pro získávání již vyšlechtěného genetického materiálu, který může být použit v hospodářských výsadbách (Ivanek et al. 2010).

3.2.3. Semenné sady

Semenné sady jsou umělé výsadby potomstev nebo klonů výběrových stromů. Jsou zřizovány za účelem šlechtění a produkce hodnotného reprodukčního materiálu. Můžeme je dělit na klonové semenné sady a jádrové semenné sady. Klonové semenné sady jsou zakládány vegetativním způsobem, zatímco jádrové semenné sady jsou zakládány z generativně vzniklých potomků výběrových stromů (Paule 1992). Semenné sady mohou být testované a netestované. Semenné sady 1. generace jsou netestované, vyšší generace jsou vždy testované. Semenné sady v České republice jsou většinou klonové, jsou zakládány z roubovanců, tedy ramet, vybraných klonů, tedy ortetů (Kaňák 2008).

3.2.3.1. Semenné sady 1. generace

Semenné sady první generace jsou zakládány rodiči, kteří jsou selektováni v lesním porostu na základě fenotypu. Jejich genetická hodnota je z velké části neznámá (Funda, El-Kassaby 2012). Genetický zisk je dosažen díky vhodnému výběru ze zdrojové populace, v tomto případě tedy z lesního porostu. Jelikož ale vybíráme pouze některé jedince, dochází ke snížení genetické diverzity. U semenných sadů 1. generace nemáme informace o genetické kvalitě jedinců. Pro výběr se tedy používá individuální fenotypová selekce. V České republice je naprostá většina semenných sadů založena tímto způsobem (Ivanek et al. 2010).

Je potřeba ponechat alespoň 50 klonů (ortetů), aby nedocházelo ke snižování variability potomstev. V blízkosti semenného sadu by se neměl nacházet porost stejného druhu, mohlo by dojít ke kontaminaci pylem. Aby se předešlo okrajovému efektu, měla by být vzdálenost okolních porostů alespoň 15–20 m (Kaňák 2008). Uspořádání ramet v rámci semenných sadů je jedním z nejdůležitějších atributů. Design semenných sadů zahrnuje jak snahy o randomizaci pro maximalizaci křížení mezi nepříbuznými klony, tak snahy vyřešit příbuznost v semenných sadech vyšších generací, aby se příbuzní jedinci křížili co nejméně a byl minimalizován inbreeding. Jedním z algoritmů, který řeší složité příbuzenské vztahy v semenných sadech a řeší uspořádání jednotlivých ramet, je *Optimum Neighborhood Algorithm* – ONA (Chaloupková et al. 2016). Příbuzenské křížení (inbreeding) u jednotlivců a populací zvyšuje genomickou homozygotnost. To může vést ke ztrátě zdatnosti. Tento jev se nazývá inbrední deprese – snížení schopnosti přežití v důsledku křížení příbuzných jedinců (Fox, Reed 2011).

Fenotypové znaky jsou velkou měrou ovlivněny prostředím. Nemůžeme tedy rovnou očekávat velkou míru genetické odezvy. Pro zvýšení genetického zisku je nutné potomstvo experimentálně testovat. Pozitivně testovaní jedinci jsou poté zařazeni do šlechtitelské populace 2. generace (Ivanek et al. 2010).

3.2.3.2. Testování potomstev semenných sadů

Genetická variabilita zkoumaných znaků a vlastností se zjišťuje pomocí testování potomstev semenných sadů. Na základě tohoto testování probíhá selekce na genetické úrovni. Ze selektovaných jedinců se vytvářejí sady vyšších generací nebo se zdrojová populace zařadí do kategorie testovaných zdrojů reprodukčního materiálu. V případě testování klonů pro vytvoření semenného sadu vyšší generace se jejich genetická hodnota zjišťuje testováním potomstev mateřských stromů – klonů (Kaňák et al. 2009). Testování pro založení semenného sadu vyšší generace lze provádět dvěma způsoby. Buď je potomstvo klonů získáno kontrolovaným křížením a jsou známi oba rodiče a vzniká plnosesterské potomstvo, nebo je známá pouze matka a jde o potomstva polosesterská (Kaňák 2008). Z plnosesterských pozitivně testovaných potomků lze zakládat semenné sady 2. a vyšší generace, z polosesterských pozitivně testovaných klonů lze založit semenný sad 1,5. generace. Pokud se u druhého způsobu zpětně zjistí otcovský klon pomocí genových markerů, mohou být z takto testovaných potomstev založeny i semenné sady vyšších generací (El-Kassaby, Lstibůrek 2009).

3.2.3.3. Semenné sady 1,5. generace

Aby mohl být semenný sad 1. generace převeden na sad 1,5. generace musí být potomstvo klonů testováno. U semenného sadu první generace se potomstvo získává z osiva, u kterého je známá pouze matka. Na základě testování se vyberou pouze jedinci s vhodnými charakteristikami. Podle výsledků testů potomstva se zpětně selektují ortety – mateřské stromy, které jsou využity pro vytvoření semenného sadu 1,5 generace. Tento způsob se nazývá zpětná selekce – „*backward selection*“ (Ivanek et al. 2010).

3.2.3.4. Semenné sady vyšších generací

Semenné sady vyšších generací můžeme založit z testovaných plnosesterských potomstev nebo z potomstev se známou matkou – polosesterských, kde se pomocí genových markerů zpětně určili i otcové (Kaňák 2008). Metoda *Breeding Without*

Breeding kombinuje fenotypový nebo genotypový výběr vhodných mateřských jedinců a kvantitativní genetickou analýzu k identifikaci otcovského genotypu. Bez potřeby kontrolovaného křížení jsou stejně určeni oba rodiče (El-Kassaby, Lstibůrek 2009). Selekcí pozitivně testovaných potomků vzniká semenný sad 2. nebo vyšší generace. Takovému typu selekce se říká „*forward selection*“ (Ivanek et al. 2010).

3.2.4. Fyziologie lesních dřevin ve šlechtění

Charakteristiky a znaky, které se používají pro selekci vhodných jedinců ve šlechtění, nemusí být pouze morfologické vlastnosti, jako přímmost kmene nebo stavba koruny. Může se jednat i o fyziologické vlastnosti. U obsah pigmentů a spektrální reflektance lze odhadnout heritabilitu v úzkém smyslu – h^2 . Tyto znaky mohou pomoci určit vhodný genotyp pomocí fenotypových projevů a vybrat tak jedince, kteří například lépe odolávají suchu nebo dalším stresům (Čepl et al. 2018).

3.3. Fenologie

Cílem fenologie je studium časového průběhu periodicky se opakujících projevů živočichu (zoofenologické fáze) i rostlin (fytofenologické fáze). Tyto projevy závisí na podnebí, půdních poměrech i na počasí. Tyto jevy nastávají každý rok, nicméně jejich termín a intenzita se různí v závislosti na proměnlivých podmínkách prostředí. Zájem o fenologii rostlin převažuje nad zoofenologií. Na základě účelu se volí pozorované objekty a stanoviště. Cílem může být hledání rozdílů v geograficky velmi blízkých stanovištích, která jsou však rozdílná. Může se pozorovat jeden rostlinný druh na více stanovištích nebo více druhů na jednom stanovišti. Pozorování může probíhat v přírodě nebo v umělých podmínkách. Může být také pozorována návaznost fenologických fází více druhů, například kvetení stromů a na něj časově navazující výskyt plísni (Krška 2006).

Lesnická fenologie se zabývá délkou produkční doby lesních dřevin, pomocí které lze stanovit přirozené oblasti pro pěstování daných druhů. Znalost fenologických fází v lese pomáhá při organizaci pěstební činnosti, v boji proti lesní škůdcům, při zvyšování produkce semen lesních dřevin nebo při volbě vhodných druhů dřevin (Polanský 1937).

3.3.1. Fenologie borovice lesní

U borovice lesní se podle metodiky ČHMÚ sledují tyto fenofáze: rašení, první listy, plné olistění, butonizace, počátek kvetení, konec kvetení a zralost plodů. U rašení se pozorují pouze terminální pupeny. Při rašení dochází k rozevření obalných šupin a špičky jehlic jsou viditelné. Nástup fenofáze rašení odpovídá dnu, kdy má borovice více než 10 % terminálních pupenů takto narašených. Fenofáze první listy odpovídá stavu, kdy jsou listy vyrostlé z koncových pupenů a jsou částečně rozvinuté. U této fáze se sledují 3 stupně nástupu této fenofáze, a to 10 %, 50 % a 100 %. Plné olistění odpovídá stavu, kdy jsou listy plně rozvinuté a dorostlé do finální velikosti. Butonizace je stav, kdy začínají být vidět nedovyvinuté samčí šištice, zaznamenává se ke dni, kdy je takto nasazeno alespoň 10 % samčích šištic. Počátek kvetení odpovídá stavu, kdy jsou šištice rozvolněné a začínají uvolňovat pyl z prašníků. Sledují se termíny, kdy tomuto stavu odpovídá 10 %, 50 % a 100 % samčích květenství. Konec kvetení je proces, během kterého samčí šištice vadnou a rozpadají se. Zaznamenává se, když 100 % květenství vykazuje konec kvetení. Zralost plodů se zaznamenává, když dorůstají šišky do konečné velikosti a začínají se otevírat. Tohoto stavu musí pro zaznamenání fenofáze dosáhnout alespoň 10 % šišek (Hájková et al. 2012). Průměrná data nástupu nedůležitějších fenofází borovici lesní jsou pro různou nadmořskou výšku uvedeny v tabulce 1.

m n. m.	Rašení 10 %	První listy 100 %	Počátek kvetení 10 %	Konec kvetení 100 %
≤ 200	25. 4.	17. 5.	8. 5.	23. 5.
201–400	29. 4.	21. 5.	12. 5.	27. 5.
401–600	3. 5.	25. 5.	16. 5.	1. 6.
601–800	9. 5.	31. 5.	21. 5.	5. 6.
≥ 800	14. 5.	3. 6.	26. 5.	10. 6.

Tabulka 1: Průměrné datum nástupu fenofáze borovice lesní podle nadmořské výšky. Zdroj: Hájková et al. (2012)

3.4. Rostlinné pigmenty

Proces, během kterého vznikají z jednoduchých anorganických látek organické látky energeticky bohaté, se nazývá oxygenní fotosyntéza. Zdrojem energie pro tento proces jsou fotony slunečního záření. Voda dodává elektrony a protony a vzniká kyslík jako vedlejší produkt, oxid uhličitý dodává uhlík pro stavbu organických látek. Rostliny využívají přibližně 40 % slunečního záření v rozsahu 400–700 nm (Tomášková, Kubásek

2016). Aby mohla vstoupit sluneční energie do procesu, musí být nejdříve absorbována rostlinnými pigmenty. Pigmenty, které se podílejí na fotosyntéze, se nacházejí v chloroplastech. Typickým fotosyntetickým pigmentem u rostlin je chlorofyl, nicméně všechny rostliny obsahují více druhů pigmentů, přičemž každý je specializován na určitou funkci (Taiz, Zeiger 2002).


Fotosyntetické pigmenty můžeme členit na tři základní skupiny: chlorofyly, karotenoidy a fykobiliny (Tomášková, Kubásek 2016). Energie, která je absorbovaná ze světla, se ukládá ve formě chemických vazeb. Tento proces závisí právě na spolupráci molekul pigmentů a skupinou molekul proteinů, které zajišťují přenos elektronů (Taiz, Zeiger 2002).

3.4.1. Chlorofyly

Nejdůležitější skupinou fotosyntetických pigmentů jsou chlorofyly. Jejich molekula je složena z konjugovaného tetrapyrolového kruhu, uvnitř kterého je navázaný hořčík, a z 20uhlíkatého řetězce. Tato struktura je zobrazená na obrázku 3. Funkcí tetrapyrolového kruhu je zachytávání fotosynteticky aktivního záření. 20uhlíkatý řetězec pak zajišťuje ukotvení molekuly chlorofylu v hydrofobním prostředí v rámci fotosystému (Taiz, Zeiger 2002). Je-li pomocí tetrapyrolového systému pohlceno záření o vhodné vlnové délce, dochází k excitaci chlorofylu. Pro zdárný průběh fotosyntézy je nutné, aby byl systém alespoň v tzv. nejnižším singletním excitovaném stavu. Energie, která dokáže zajistit excitaci, je shodná s energií červeného světla. Modrá část viditelného spektra způsobí excitaci do druhého singletního excitovaného stavu. (Tomášková, Kubásek 2016). Absorpční maxima chlorofylu se tedy nacházejí v modré (asi 430 nm) a červené (asi 660 nm) části spektra. Zelené světlo není absorbováno a je tedy odraženo nebo propuštěno skrz fotosyntetický orgán. To dává rostlinám jejich zelenou barvu (Taiz, Zeiger 2002). Relativní absorbance chlorofylů je zobrazena na obrázku 4. Pokud nemůže excitovaný chlorofyl energii předat, buď z důvodu přebytku světla, nebo kvůli působení stresoru, je přebytečná energie vyzářena fluorescencí nebo ve formě tepla. Fluorescence je důležitým parametrem, který může být využit k hodnocení zdravotního stavu rostliny nebo fotosyntézy. V rámci fotosystému nacházíme 2 typy chlorofylů. Chlorofyl *a*, který přenáší elektron na jinou molekulu a chlorofyl *b*, který předává energii chlorofylu *a*. (Tomášková, Kubásek 2016).

3.4.2. Karotenoidy

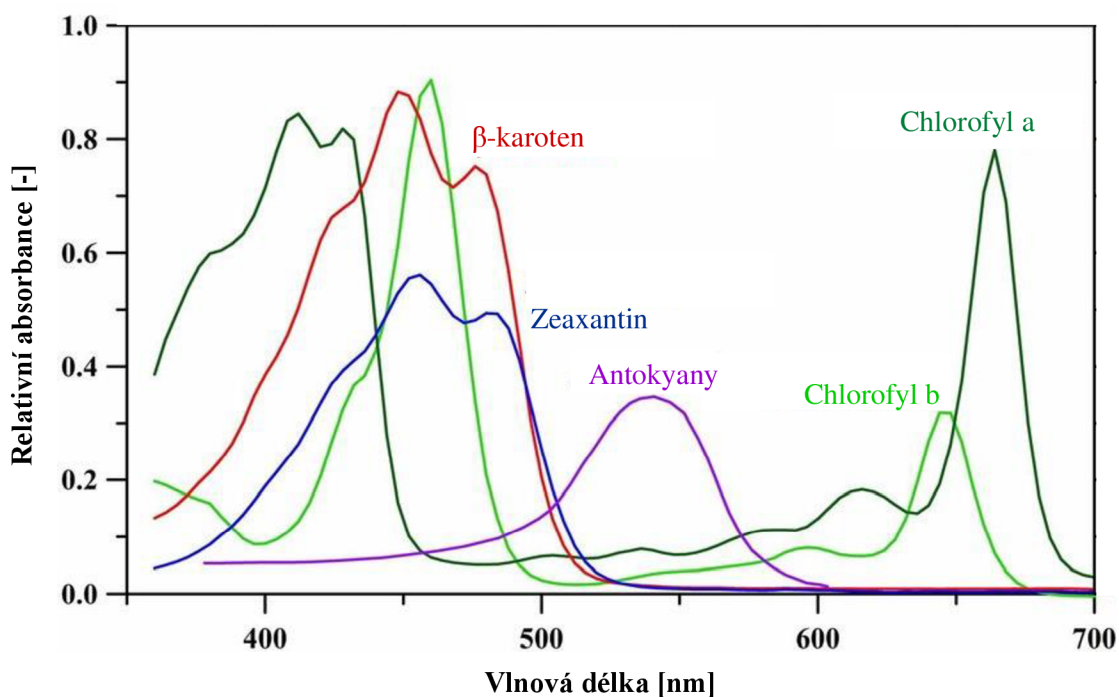
Mimo chlorofyly patří mezi fotosyntetické pigmenty také karotenoidy. Skládají se ze 40uhlíkatých tetraterpenů. Základní stavební jednotkou pro vznik karotenoidů jsou izoprenové jednotky (8 izoprenových jednotek). Tato struktura je zobrazena na obrázku 3. Karotenoidy lze rozdělit na kyslíkaté xantofyly (například zeaxantin) a bezkyslíkaté karoteny (například β -karoten). Nalézáme je zejména v chromoplastech, jejichž zásluhou získávají barvu květy nebo plody. Mají i fotosyntetickou funkci. Některé xantofyly předávají energii chlorofylům a podílí se tak na fotosyntéze. Účinnost přenosu energie je ale pouze 30 %. Další funkce karotenoidů je ochrana fotosyntetického aparátu před oxidativním stresem. Reaktivní formy kyslíku a dusíku, vznikající zejména při vysoké ozáření, přeměňují karotenoidy na neškodné molekuly pomocí svých antioxidačních vlastností. Další způsob ochrany je přeměna nadměrné energie na teplo, ještě před vznikem těchto nebezpečných radikálů. (Tomášková, Kubásek 2016). Relativní absorpance karotenoidů je zobrazena na obrázku 4.



Obrázek 3: Struktura chlorofylů *a* a *b* (A) a β -karotenu (B). Zdroj: přeloženo dle Taiz, Zeiger (2002).

3.4.3. Antokyany

Antokyany jsou pigmenty, které dodávají barvu jak listům rostlin, tak jejich plodům a květům. Hrají tak zásadní roli při opylování nebo rozšiřování semen. Mají však i jiné funkce. Můžou působit jako antioxidanty nebo antibakteriální látky. Společně s dalšími látkami hrají roli v odolnosti rostlin proti hmyzu. Bylo prokázáno že antokyany chrání listy bavlníku před motýlem *Chloridea virescensse* (Kong et al. 2003). Další prokázanou rolí antokyanů je zvyšování odolnosti proti stresu chladem. Se zvyšujícím se chladem se zvyšuje i syntéza antokyanů, nicméně není známo, jakými přesně procesy antokyany odolnosti prospívají. Semenáčky stromů často hromadí antokyany ve větším množství než dospělci (Chalker-Scott 1999). Absorpční maximum antokyanů se pohybuje okolo 530 nm (Ahliha et al. 2018). Relativní absorbance antokyanů je zobrazena na obrázku 4.




Obrázek 4: Absorbanční křivky rostlinných pigmentů. Zdroj: přeloženo podle Durazzo (2021).

3.5. Spektroskopie a spektrometrie

Spektroskopie je věda, která se zabývá interakcemi záření s hmotou. Historicky se jednalo pouze o elektromagnetické záření, nicméně v současnosti mohou být v širším smyslu zahrnuty i jiné formy energie. Jedná se například o akustické vlny nebo paprsky částic jako jsou ionty nebo elektrony (Skoog et al. 2018). Spektroskopie dokáže velmi přesně odlišit specifické chemické vazby v materiálech, ať už pevných, kapalných nebo plyných. Výhodou spektroskopie, na rozdíl od jiných metod, jako je například

rentgenová difrakce, je schopnost odlišit krystalické a amorfní typy materiálů. Spektroskopie dokáže rozeznat i drobné změny v chemii nebo struktuře materiálů (Rencz, Ryerson 1999). Spektrometrie a její metody se týkají měření intenzity záření pomocí fotoelektrického převodníku nebo jiného typu elektronického zařízení (Skoog et al. 2018).

Spektroskopii můžeme rozdělit na laboratorní a obrazovou. Laboratorní spektroskopie používá k měření spektrometry. Spektrometry neposkytují obrazová data, ale pouze jednotlivé spektrální křivky měřených objektů. Obrazová spektroskopie naopak poskytuje obrazová data, kde je každý pixel opatřen svojí spektrální charakteristikou. Tato data mají formu datové kostky („*datacube*“), kde je pro každý pixel v každé vrstvě jeho spektrální odpověď pro danou vlnovou délku nebo kanál (Albrechtová et al. 2017). Obrázek 5 vizualizuje spektrální data ve formě *datacube*.



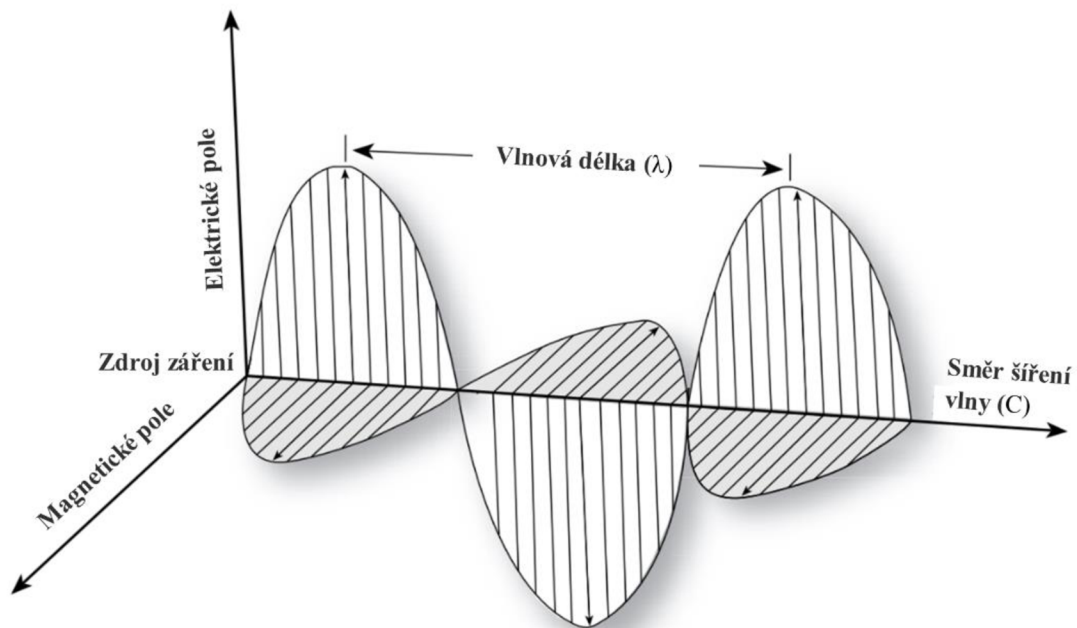
Obrázek 5: Spektrální data ve formě datové kostky (*datacube*). Zdroj: Jensen (2014).

3.5.1. Elektromagnetické záření

Elektromagnetické záření můžeme vyjádřit pomocí elektromagnetické vlny, která je složena z elektrického a magnetického pole. Tyto dvě složky kmitají kolmo na sebe i kolmo ke směru šíření energie. Schéma takovéto vlny je zobrazené na obrázku 6. Elektromagnetické záření je charakterizováno pěti veličinami, které zároveň poskytují informace o sledovaném objektu. Jedná se o směr šíření vlny (C), intenzitu (I), vlnovou délku (λ), polarizaci a fázi (Jacquemoud, Ustin 2019).

SI jednotkou vlnové délky je metr, nicméně vlnová délka může být vyjádřena i v dalších jednotkách vhodných pro daný účel. V této práci budou nejčastěji používány nanometry (nm) nebo mikrometry (μm), které jsou vhodnou a nejčastěji užívanou jednotkou pro

vlnové délky ve viditelné až krátkovlnné infračervené části elektromagnetického spektra (Jacquemoud, Ustin 2019).



Obrázek 6: Elektromagnetická vlna a její charakteristiky. Zdroj: přeloženo podle Jensen (2014).

V praxi se pro lepší orientaci často specifikuje konkrétní část elektromagnetického spektra. Elektromagnetické záření použitelné pro studium vegetace se pohybuje od 400 nm do 2500 nm. Viditelnému záření (VIS) odpovídá 400–750 nm (Albrechtová et al. 2017). Obvykle si představujeme viditelné záření jako světlo složené z energie v modrém (400–500 nm), zeleném (500–600 nm) a červeném (600–700 nm) kanálu elektromagnetického spektra (Jensen 2014). Blízké infračervené záření (NIR) odpovídá 750–1200 nm a oblast krátkovlnného infračerveného záření (SWIR) se nachází mezi 1200–2500 nm (Albrechtová et al. 2017). Uvedené hodnoty se mohou lišit dle autora, například Jacquemoud a Ustin (2019) uvádí hodnoty VIS mezi 360–760 nm, hodnoty NIR mezi 760–1400 nm a hodnoty SWIR mezi 1400–3000 nm.

3.5.2. Interakce energie a hmoty

Podíl energie záření a času, za který byla tato energie vyzářena se nazývá zářivý tok – Φ . Jedná se tedy o vyprodukovanou energii za jednotku času, proto je zářivý tok měřen ve wattech (W). Pokud se zabýváme pouze energií některého spektrálního kanálu, jedná se o spektrální zářivý tok. Při kontaktu s povrchem nastávají 3 jevy. Energie se odráží od povrchu, energie prochází povrchem, anebo je energie materiálem, na který naráží, absorbována. Z toho lze vyvodit bilanční rovnici zářivého toku. Celková hodnota

zářivého toku při specifických vlnových délkách Φ_i dopadající na objekt musí být rovna součtu množství zářivého toku odraženého od povrchu Φ_ρ , množství zářivého toku absorbovaného povrchem Φ_α a množství zářivého toku procházejícího povrchem Φ_τ (Jensen 2014). Tento vztah je vyjádřen v rovnici 1.

$$\Phi_{i\lambda} = \Phi_{\rho\lambda} + \Phi_{\alpha\lambda} + \Phi_{\tau\lambda} \quad (1)$$

Tyto veličiny pracují s energií přicházející z jakéhokoliv úhlu polokoule nad objektem. Označujeme je tedy jako hemisférické.

Podíl odraženého zářivého toku a celkového zářivého toku se nazývá reflektance nebo odrazivost, podíl absorbovaného zářivého toku a celkového zářivého toku se nazývá absorpance a podíl zářivého toku procházejícího povrchem a celkového zářivého toku se nazývá transmitance (Jensen 2014). Tyto podíly lze opět vyjádřit v bilanční rovnici (rovnice 2):

$$\frac{\Phi_{i\lambda}}{\Phi_{i\lambda}} = \frac{\Phi_{\rho\lambda}}{\Phi_{i\lambda}} + \frac{\Phi_{\alpha\lambda}}{\Phi_{i\lambda}} + \frac{\Phi_{\tau\lambda}}{\Phi_{i\lambda}}$$

nebo

$$i_\lambda = \rho_\lambda + \alpha_\lambda + \tau_\lambda \quad (2)$$

kde ρ_λ je spektrální hemisférická reflektance, α_λ je spektrální hemisférická absorpance a τ_λ je spektrální hemisférická transmitance. Pro tuto práci je zajímavá právě reflektance, ta je vyjádřena v rovnici 3:

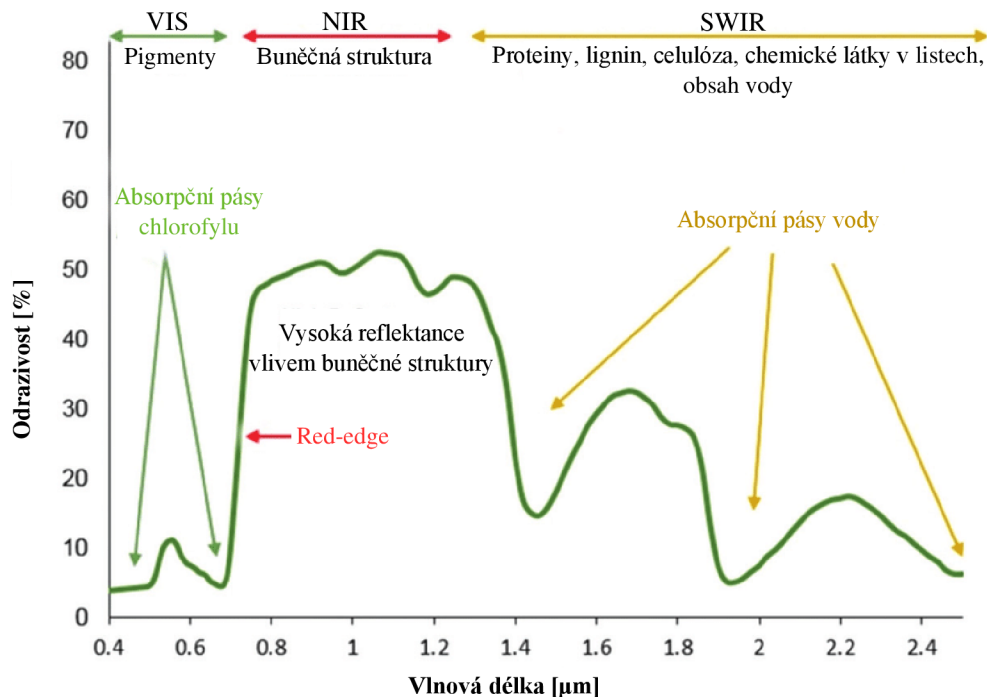
$$\rho_\lambda = i_\lambda - (\alpha_\lambda + \tau_\lambda) \quad (3)$$

reflektance je tedy bezrozměrná veličina určující množství záření, které nebylo absorbováno nebo neprošlo povrchem objektu (Jensen 2014).

3.5.3. Křivka spektrální odrazivosti

Každý materiál a jeho povrch má jiné spektrální vlastnosti. Tyto vlastnosti lze popsat pomocí reflektanční křivky, také nazývané jako křivka spektrální odrazivosti. Křivka zobrazuje závislost reflektance na vlnové délce. Ukazuje, z kolika procent byly snímané vlnové délky odrazeny. Různé materiály mohou určité vlnové délky odrážet stejně nebo

podobně účinně. Například voda a vegetace mohou mít v oblasti VIS podobné hodnoty reflektance. Nicméně při širším pohledu na celé spektrum se materiály odlišují (Albrechtová et al. 2017). Reflektanční křivka vegetace je vyobrazena na obrázku 7.



Obrázek 7: Křivka spektrální odrazivosti s uvedenými hlavními absorpčními a reflektančními vlastnostmi. Zdroj: upraveno dle Roman, Ursu (2016).

3.5.4. Spektrální rozlišení

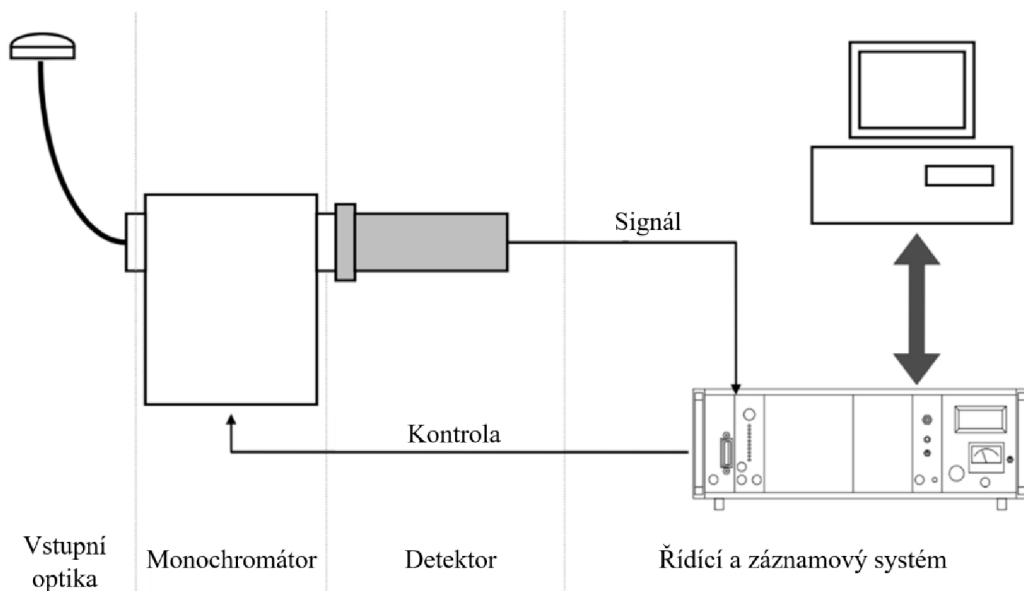
Do spektrálního rozlišení spadá počet a šířka snímaných intervalů vlnových délek elektromagnetického záření. Tyto intervaly nazýváme pásma nebo kanály. Spektrální rozlišení závisí na přístroji, který používáme k měření (Jensen 2014). Hyperspektrální data obsahují řádově stovky snímaných intervalů. Obvykle se jejich šířka pohybuje od 3 do 15 nm a tyto intervaly na sebe navazují (Albrechtová et al. 2017). Některé analýzy vyžadují takto přesná data. Například určení pozice červeného okraje („red-edge“) je na hyperspektrálních datech závislé (Jensen 2014). Multispektrální data obsahují pouze jednotky intervalů. Tyto intervaly obvykle bývají širší a zahrnují pouze některé vlnové délky. Šířka intervalů se pohybuje od desítek až po stovky nanometrů (Albrechtová et al. 2017).

Navzdory výhodám spektrálních snímků obsahují téměř všechna obrazová data, které zaznamenáváme, pouze 3 měření. Jedná se o tři vážené spektrální průměry přes oblast

červené, zelené a modré části VIS. Při této formaci RGB obrazu je tedy ztraceno mnoho spektrální informace (Lin, Finlayson 2020).

3.5.5. Spektroradiometr

Spektroradiometry měří světlo, ať už se jedná o světlo přímo ze zdroje nebo světlo odražené od materiálu. Konkrétní jednotky měření závisí na vstupní optice. Jedná se o ozářenost nebo zářivost (Berns 2019). Pro získání procentuální reflektance potřebujeme ještě množství energie odražené od stoprocentně odrazivého povrchu. Jednoduchou matematickou úpravou pak můžeme získat hodnoty reflektance, absorbance nebo transmitance (Jensen 2014). Spektroradiometry jsou přístroje používané v laboratorní spektroskopii. Poskytují spektrální křivku měřených materiálů. Každý spektroradiometr se skládá ze čtyř základních komponent. Vstupní optika shromažďuje záření ze zorného pole a přivádí ho k monochromátoru. Monochromátor rozděljuje přicházející záření na jednotlivé paprsky. Jednotlivé složky světla poté míří k detektorům, které měří v hodnotu elektromagnetického záření každého paprsku. Data poté upravuje a ukládá řídicí a záznamový systém (Bentham Instruments Ltd. 1997). Jednoduché schéma takového spektroradiometru se nachází na obrázku 8.



Obrázek 8: Schéma spektroradiometru. Zdroj: přeloženo dle Bentham Instruments Ltd. (1997).

3.5.6. Spektrální reflektance vegetace

Pro správnou interpretaci spektrálních křivek je nutná znalost vzájemného působení mezi slunečním zářením a vegetací. Živé rostliny obvykle vykazují poměrně nízkou odrazivost

v oblasti viditelného spektra. To je způsobeno silnou absorpcí rostlinných barviv, zejména chlorofylů, avšak karotenoidy, xantofyly nebo antokyany také nesou svůj podíl. Poměrně vysoká odrazivost v oblasti NIR je způsobena vnitřní stavbou listů. Odrazivost vlnových délek v oboru nad 1300 nm je naopak poměrně nízká, a to zejména kvůli silné absorpci vodou. (Knipling 1970). Odrazivost listu závisí na povaze jeho povrchu. Například může být zvýšena hustou pokrývkou trichomů nebo silnou vrstvou vosku (Taiz, Zeiger 2002).

3.5.6.1. Spektrální reflektance vegetace v oblasti viditelného záření

Většina záření v oblasti VIS je přenášena skrz kutikulu a epidermis k buňkám palisádového a houbového parenchymu. Právě v těchto buňkách se nachází chloroplasty obsahující chlorofyly, které absorbují poměrně velkou část přicházejícího spektra (Jensen 2014). S tím úzce souvisí nízké procento reflektance, okolo 10 %. Maximum reflektance se nachází okolo 550 nm v oblasti zeleného světla. Tento vrchol je odpovědný za zelenou barvu rostlin, kterou lidské oko vnímá (Knipling 1970). Listy v oblasti VIS odrážejí v průměru 6–10 % dopadajícího záření. Zelené světlo se odráží velmi silně (10–20 %), oranžové a červené světlo se odráží nejméně, do 10 % (Larcher 2003). Odrazivost bude tím nižší, čím bude vyšší absorpce způsobená právě např. pigmenty. Maximální absorpční účinnost chlorofylu *a* se nachází okolo vlnových délek 430 nm a 660 nm. Maximální absorpce chlorofylu *b* se nachází na vlnových délkách 450 nm a 650 nm (Albrechtová et al. 2017). Přítomny jsou zde ale i jiné pigmenty. Žluté karoteny a světle žluté xantofyly mají svá absorpční maxima převážně v oblasti modré barvy. Absorpční spektrum β -karotenu absorbuje nejvíce vlnové délky okolo 450 nm. V listech se mohou nacházet i pigmenty fykoerythrinu, které absorbují převážně v zelené oblasti kolem 550 nm, což umožňuje odrazit modré a červené světlo. Fykocyanin absorbuje převážně v zelené a červené oblasti s maximem kolem 620 nm. Jelikož mají chlorofyly *a* a *b* podobná absorpční pásma, mají tendenci dominovat a zakrývat účinek ostatních přítomných pigmentů (Jensen 2014).

3.5.6.2. Spektrální reflektance vegetace v oblasti red-edge (červeného okraje)

Odrazivost zdravých listů se dramaticky zvyšuje v oblasti 700–1200 nm. Jde o spektrální projev vegetace v oblasti blízkého infračerveného záření. K prudkému nárůstu odrazivosti dochází mezi vlnovými délkami cca 700–800 nm. Tato oblast se označuje

jako červený okraj – red-edge. Pravděpodobně se jedná o nejprozkoumanější oblast spektra, jelikož má veliký význam pro hodnocení fyziologického stavu rostlin (Albrechtová et al. 2017). K prudkému nárůstu reflektance dochází mezi oblastí silné absorpce chlorofylu okolo 680 nm a vysoké reflektance v oblasti NIR. Vyšší odrazivost je způsobena vnitřní stavbou listu. Kratších vlnové délky jsou rozptýleny a odraženy díky změnám prostředí uvnitř listu. To slouží rostlině jako obrana proti přehřátí (Jensen 2014).

Důležitým parametrem je poloha REIP („*red-edge inflexion point*“). Poloha REIP je v bodě, kde se mění spektrální křivka z konvexní na konkávní s maximálním sklonem na spektru odrazu vegetace mezi červenými a blízkými infračervenými vlnovými délkami. Red-edge je užitečný, protože silně koreluje s obsahem chlorofylu v listech a může sloužit jako citlivý indikátor stresu rostliny. Zároveň se používá při výpočtech některých vegetačních indexů (Čepl et al. 2018). Pokud absorpce chlorofylu v rostlině klesá, zmenšuje se i celková šířka absorpčního pásma. S klesajícím obsahem chlorofylu se REIP posouvá do krašších vlnových délek. Naopak s nárůstem chlorofylu se posouvá do oblasti s delšími vlnovými délkami. To může být signálem pro končící vegetační období rostliny, špatný fyziologický stav nebo stresový stav rostliny (Jensen 2014)

3.5.6.3. Spektrální reflektance vegetace v oblasti NIR

V oblasti NIR vykazuje vegetace vysoké procento reflektance. Tato vysoká odrazivost je způsobena vnitřní buněčnou strukturou. Kutikulární vosk na listu a epidermis jsou pro infračervené záření téměř zcela prostupné a pouze malé množství sluneční energie dopadající na list je odraženo přímo z jeho vnějšího povrchu. Záření prostupuje a rozptyluje se skrz kutikulu a epidermis k mezofylovým buňkám a vzduchovým dutinám vnitřku listu. Vzhledem k rozdílným prostředím, a tedy rozdílným indexům lomu světla dochází k dalším lomům a rozptýlení světla. K absorpci infračerveného záření v rozsahu 700–1300 nm téměř vůbec nedochází. Na druhou stranu 40–60 % z něj je rozptýleno a vyzářeno nazpět a zbytek je rozptýlen směrem dolů a označen jako transmitované záření (Knipling 1970).

Pokud energie NIR byla rostlinou absorbována se stejnou účinností jako ve viditelné oblasti, mohly by se tyto části vystavené tomuto záření přehřát a proteiny by mohly začít denarovat. Toto obrovské množství energie proto rostliny nevyužívají a jednoduše ho odrážejí nebo propouštějí do spodnějších listů či země (Jensen 2014). V blízké

infračervené oblasti (NIR) závisí spektrální projev na vnitřní struktuře listu, např. na objemu mezibuněčných prostor. S přibývajícím věkem jedince nebo se zvýšeným stresem z nedostatku vody se mění turgor v jednotlivých buňkách a mění se tedy i objem vzduchu v mezibuněčných prostorech. Oblast NIR je tedy použitelná pro zjišťování zdravotního stavu vegetace. V některých případech může být dokonce vhodnější než jiné části spektra, ve kterých se nacházejí absorpční maxima zkoumaných látek. Například při vysokém obsahu vody se hlavní absorpční pásy vody blízko 1450 nm, 1940 nm a 2500 nm saturují, takže oblasti střední absorpce blízko 1650 nm a 2200 nm a slabé absorpční pásy blízko 970 nm a 1200 nm mohou být citlivější na rozdíly v obsahu vody v listu (Jacquemoud, Ustin 2019).

3.5.6.4. Spektrální reflektance vegetace v oblasti SWIR

Při vlnových délkách delších než 1100 nm začíná reflektance a transmitance klesat. Záření je absorbováno zejména vodou okolo 1200 nm, 1400 nm, 1900 nm a 2500 nm v čerstvých listech a případně sušinou v listech suchých. Odrazivost suchého listu je obvykle větší než odrazivost živého listu při všech vlnových délkách (Jacquemoud, Ustin 2019).

3.5.7. Spektrální reflektance a heritabilita

Různé rostliny, druhy a linie si vyvinuly odlišné mechanismy pro získání a využití zdrojů. Důsledkem je rozdíl v obsahu chemických látek, ale i ve stavbě rostlinných orgánů. Tyto rozdílnosti v chemickém složení a vnitřní stavbě rostliny se projevují ve spektrální odpovědi. Spektrální křivku můžeme chápat jako vyjádření chemického a strukturálního složení rostlin, přičemž toto složení bývá podobnější uvnitř jednoho druhu, avšak rozdíly se vyskytují i v rámci jednoho druhu. Spektra mohou být využita pro odhad evoluční příbuznosti mezi organismy v rámci jednoho druhu, ale i mezi liniemi (Cavender-Bares et al. 2016).

V současnosti jsou znalosti o genetické variabilitě a spektrální odrazivosti u lesních dřevin omezené. Obsah pigmentů a jejich spektrální vlastnosti související s h^2 mohou být pro šlechtitelské programy zásadní. Tyto vlastnosti lze použít jako nepřímé identifikátory požadovaných fenotypů a využít je např. k identifikaci genotypů odolných vůči suchu nebo tolerantních vůči stresu (Čepl et al. 2018).

Bylo prokázáno, že populace v rámci druhu lze pomocí spektrálních dat odlišit. Na rodu dubu (*Quercus*) byla zkoumána proměnlivost pomocí spektrálních dat v rámci celého rodu, tak v rámci druhů. Jednotlivé populace byly pomocí spektrálních dat odlišeny. Zároveň bylo prokázáno, že spektrální podobnost je významně spojena s fylogenetickou podobností mezi druhy. Přesnost rozlišení se zvyšuje na vyšších úrovních v hierarchické organizaci rostlinné diverzity. Lépe se tedy rozliší klady, než druhy nebo populace (Cavender-Bares et al. 2016).

Studie ukázaly, že jednotlivé populace v rámci jednoho druhu mohou být odlišeny pomocí spektrálních dat. Tato spektrální data mohou být použita v rámci genomické selekce. Genomická selekce spočívá ve spojení fenotypových dat a molekulárních markerů k vytvoření prediktivního modelu, který lze následně použít k predikci vlastností jedinců, kteří nemusí být předem fenotypováni. Studie prováděná na listech a zrnech pšenice seté (*Triticum aestivum*) a dřevě topolu černého (*Populus nigra*) ukázala, že pro druhy i jednotlivé tkáně byla genomická heritabilita podél spektra vysoce proměnlivá s vrcholy okolo 60 %. To ukazuje na silné polygenetické signály pro některé vlnové délky. Tyto vlnové délky pak mohou být použité pro genomickou selekci (Rincant 2018).

Na jehličnanech mnoho studií prováděno nebylo. Jedna ze studií řešila heritabilitu pomocí spektrální odrazivosti jehlic u dvou populací borovice lesní, a to zejména v oblasti red-edge. U vybraných stromů byl rekonstruován rodokmen pomocí DNA markerů. Fenotyp pigmentových a spektrálních znaků tak bylo možné rozložit na jednotlivé genotypové složky a odhadnout tak h^2 . Maximální odhad h^2 byl nalezen na vlnové délce 722 nm. To odpovídá poloze inflexního bodu v oblasti red-edge. Poměrně vysoké byly také hodnoty v oblasti NIR a SWIR. Naproti tomu všechny odhady h^2 v oblasti VIS mimo pásmo zeleného světla se blížily nule. Znalost těchto markerů založených na pigmentech nebo spektrální odrazivosti je použitelná pro rozpoznávání odolných genotypů. Navíc mohou být spektrální indexy použité jako nepřímé ukazatele konkrétních parametrů, které jsou závislé na produkčních nebo adaptivních vlastnostech (Čepl et al. 2018).

Další studie, ze které z velké části vychází i tato diplomová práce, byla prováděna na třech populacích borovice lesní. Byly použity dva přístupy měření hyperspektrálních dat – pomocí kontaktní sondy s vlastním zdrojem světla a pomocí optického kabelu bez světelného zdroje. Rozsah měření odpovídal 350–2500 nm. Pomocí obou metod byly

nalezeny statisticky významné rozdíly v celém měřeném spektru mezi jednotlivými populacemi. Zároveň na základě spektrálních dat byl vytvořen model, který s přesností 83 % dokázal rozřadit jedince do jednotlivých populací. Rozdíl mezi populacemi lze chápat jako důkaz rozdílné lokální adaptace (Stejskal et al. 2023).

3.6. Kolorimetrie

Kolorimetrie je vědní obor, jehož cílem je fyzikální specifikace světelných podnětů, které vytvářejí daný barevný vjem v určitých pozorovacích podmínkách. Narozdíl od spektroskopie je kolorimetrie omezena na oblast viditelného světla. Její snahou je znázornění rozložení spektrální síly dopadajícího světla pomocí nízkého počtu parametrů (obvykle tří). Kolorimetrie se zabývá zejména přesným určováním barev, a také barevných rozdílů, pokud se dva podněty neshodují. Kolorimetrická data sama o sobě nespécifikují, jakou barvu uvidíme. Cílem je specifikace fyzikálních aspektů barevných podnětů, nikoli barevný vzhled (Lee 2005).

3.6.1. Barevné systémy

Pokusy o organizace rozsáhlé palety barev, kterou člověk dokáže rozeznat, se objevují již od starověku. Mimo vědce své vlastní systémy barev navrhovali také slavní filozofové, architekti, umělci nebo spisovatelé. Za zmínku stojí např. Aristoteles, Leonardo da Vinci, Isaac Newton nebo Johann W. Goethe. Dvacáté století je plné dalších představitelů, kteří vytvářeli barevné systémy, např. Albert H. Munsell nebo Harald Küppers. Snahu o vytvoření barevného systému měly také různé organizace, např. Commission Internationale de l'Eclairage (CIE), Optical Society of America, Swedish Standards Institution (Shamey 2023).

Systém uspořádání barev, barevný systém nebo také barevný model se snaží všechny barvy definovat v rámci topologického modelu, přičemž každé barvě přiřazuje specifickou pozici a navrhuje určitý druh logiky, která určuje celou organizaci. Tyto modely přijaly podle různých autorů a v průběhu času nejrůznější tvary a různé dimenze: lineární škály, chromatické kruhy, barevné trojúhelníky nebo barevná tělesa. Tělesa měla různá řešení, jako jsou krychle, kužely, pyramidy, dvojité kužely, dvojité pyramidy, koule a více či méně nepravidelná tělesa (Shamey 2023).

Vynásobením spektrální intenzity záření zdroje světla $L(\lambda)$ a spektrální reflektance $R(\lambda)$ získáme spektrální intenzitu odraženého záření $Spec(\lambda)$. Rovnice 4 zobrazuje tento vztah:

$$Spec(\lambda) = L(\lambda) \cdot R(\lambda) \quad (4)$$

Ta je následně násobena s jednotlivými kolorimetrickými funkcemi $F_R(\lambda)$, $F_G(\lambda)$, $F_B(\lambda)$. Suma hodnot získaných z jednotlivých funkcí poté vyjadřuje intenzitu červené I_R , zelené I_G a modré I_B barvy v rámci spektra. Tyto vztahy jsou vyjádřeny v rovnicích 5–7:

$$I_R = \sum_{(\lambda=380-780)} Spec(\lambda) \cdot F_R(\lambda) \quad (5)$$

$$I_G = \sum_{(\lambda=380-780)} Spec(\lambda) \cdot F_G(\lambda) \quad (6)$$

$$I_B = \sum_{(\lambda=380-780)} Spec(\lambda) \cdot F_B(\lambda) \quad (7)$$

Tyto intenzity je nutné normalizovat. To je provedeno jako podíl intenzity jedné barvy a sumy intenzit všech tří barev. Normalizaci zobrazují rovnice 8–10:

$$R = \frac{I_R}{I_R + I_G + I_B} \quad (8)$$

$$G = \frac{I_G}{I_R + I_G + I_B} \quad (9)$$

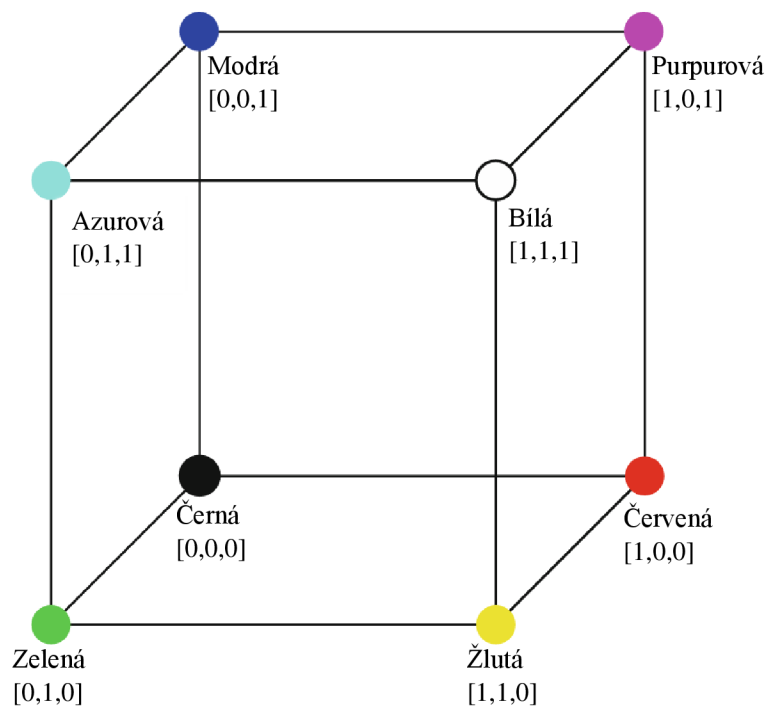
$$B = \frac{I_B}{I_R + I_G + I_B} \quad (10)$$

Tyto hodnoty poté určují barvu v daném barevném systému, ať už jde o RGB nebo XYZ, podle použitých kolorimetrických funkcí. Tyto systémy lze ale vzájemně převést (Kasajima 2019) .

3.6.3. Systém RGB

Systém RGB je jedním z nejjednodušších. Jedná se o systém míchání světla různých barev. Systém lze jednoduše vysvětlit na barevném displeji. Pokud je množství základních barev na jejich minimu, výsledkem bude černý displej. V případě, že je množství těchto tří barev na maximu, výsledkem bude bílý displej. Snižování a zvyšování jednotlivých základních

barev nebo jejich různých kombinací vede k systematickému uspořádání barev. Toto uspořádání má tvar krychle, která má ve svých vrcholech primární barvy, sekundární barvy, bílou a černou barvu. Mezi primární barvy patří červená, zelená a modrá, jejich anglické názvy *red*, *green* a *blue* daly název tomuto systému. Mezi sekundární barvy patří kombinace vždy dvou základních barev v jejich maximální hodnotě. Jde o barvu purpurovou, složenou z červené a modré, žlutou složenou z červené a zelené a azurovou, složenou ze zelené a modré. Bílá, jak již bylo vysvětleno na příkladu s displejem, je složenou ze všech základních barev při jejich maximálních hodnotách – červené, zelené a modré. Černá barva naopak odpovídá nulové intenzitě všech barev (Berns 2019). Toto uspořádání spolu s kartézskými souřadnicemi takového systému je uvedeno na obrázku 10.



Obrázek 10: Model systému RGB s kartézskými souřadnicemi základních a sekundárních barev. Zdroj: přeloženo dle Chen et al. (2012)

3.6.4. Systém HSV

Tvorba barvy pomocí RGB není intuitivní a vyžaduje jisté znalosti. Pro lepší orientaci lze převést systém RGB na systém s intuitivními pojmy. Nejčastěji používané jsou odstín („*hue*“), sytost („*saturation*“) a jas („*brightness*“), které dohromady určují název tohoto systému – HSB. Pojem jas je často zaměňován s pojmem hodnoty („*value*“), nicméně jejich význam je shodný. Tato záměna poté dává systému jméno HSV (Berns 2019).

Odstín je chápán jako typ barvy. Jde například o červenou, žlutou nebo fialovou. Odstín se vztahuje pouze na chromatické (živé) barvy. Chromatické barvy, jsou veškeré barvy mimo černou, bílou a šedou. Tyto tři barvy se označují jako achromatické. Právě tato chromatičnost nebo achromaticnost je vyjádřena sytostí, někdy překládanou jako živostí. Achromatické barvy mají úroveň sytosti 0 %. Zcela saturované barvy, jako je např. čistá zelená jsou saturovány ze 100 %. Středně živé barvy jako např. šedozeleň, mají střední hodnoty sytosti (Kasajima 2019). Hodnota jasu udává světlost nebo tmavost barvy. Vyjadřuje, kolik světla se barva odráží (Berns 2019).

Tento barevný prostor může být znázorněn pomocí kuželu nebo válce. Odstín je určen pomocí úhlu v rozsahu od 0° do 360°. Červená barva odpovídá 0°, zelená 120°, modrá 240° a na modrou opět navazuje červená barva. Sytost a jas jsou definovány pomocí procent a doplňují odstín při vytváření plné barvy (Kim 2018). Tento systém je zobrazený na obrázku 11.

Systém HSV vychází z RGB systému a tyto systémy jsou tedy vzájemně převeditelné. Pro převod ze systému RGB na HSV Berns (2019) uvádí následující rovnice 11–16:

$$H = \begin{cases} ATAN2(\beta, \alpha) \frac{180}{\pi} & ATAN2(\beta, \alpha) \geq 0 \\ ATAN2(\beta, \alpha) \frac{180}{\pi} + 360 & ATAN2(\beta, \alpha) < 0 \end{cases} \quad (11)$$

$$S = 100 \frac{\Delta}{\max(R, G, B)} \quad (12)$$

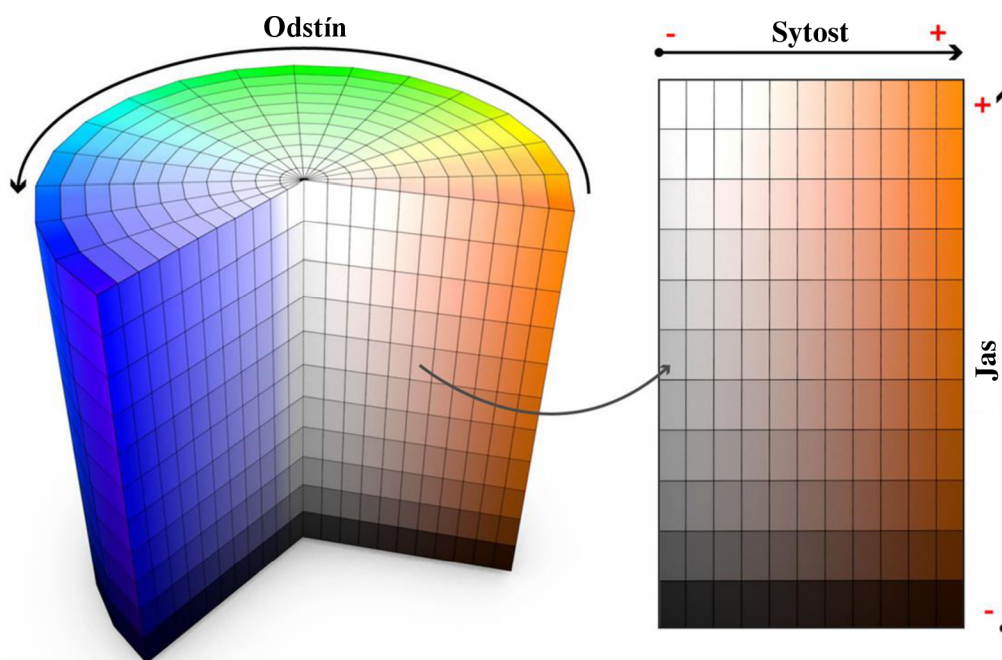
$$V = 100 \frac{\max(R, G, B)}{255} \quad (13)$$

kde

$$\alpha = \frac{2R - G - B}{2} \quad (14)$$

$$\beta = \frac{\sqrt{3}(G - B)}{2} \quad (15)$$

$$\Delta = \max(R, G, B) - \min(R, G, B) \quad (16)$$



Obrázek 11: Model systému HSV. Zdroj: přeloženo dle Kim (2018).

3.6.5. RGB a barva listu

Chlorofyl je užitečným indikátorem celkového zdravotního stavu rostliny. Stanovení obsahu chlorofylu, jakožto pigmentu nutného pro průběh fotosyntézy, a tedy nutného pro růst rostliny, může být použito ke zkoumání fyziologického stavu rostliny a má důležité dopady na detekci stresu a škůdců. Tento fyziologický stav má jisté kolorimetrické odezvy na barvě rostlin. Nedostatek minerálů se projevuje barevnými změnami, které mohou být odhaleny pomocí RGB dat. Nedostatek dusíku a nedostatek železa způsobují chlorózu, změnu barvy zelené na žlutozelenou nebo žlutou. Ta je způsobována také nedostatkem síry, chloru, boru, zinku, hořčíku nebo manganu. Nedostatek různých živin se ale může projevovat odlišně. Nedostatek dusíku způsobuje chlorózu celého listu, zatímco nedostatek železa často vytváří chlorotické pruhy. Nedostatek fosforu zbarvuje listy do tmavě zelené nebo nachové a nedostatek draslíku vytváří bílé skvrny (Kasajima 2019).

Používání RGB obrazových dat pro analýzu obsahu chlorofylu a jiných pigmentů není v praxi příliš zavedené. Proto existují studie spíše pro zemědělské plodiny a studie, které by se zabývaly odhadem pigmentů pomocí RGB u stromů chybí. Nicméně poznatky zjištěné u zemědělských plodin mohou být do jisté míry aplikovány i na stromy. Studie prováděná na čiroku korelovala hodnoty RGB s obsahem chlorofylu ukázala dobrou shodu mezi hodnotou G a obsahem chlorofylu. Kanály R a B tak vysokou shodu

nevykazovaly. Zároveň z hodnot RGB byly spočítány hodnoty H (odstín), S (saturace) a I (intenzita). Parametry H, S a I byly vybrány z barevného prostoru, protože lépe odpovídají způsobu, jakým lidé vnímají barvu než soubor parametrů RGB. Pomocí HSI lze kvantifikovat viditelnou "zelenost" listů a porovnat ji. Byla pozorována významná korelace mezi parametrem S a obsahem chlorofylu, zatímco slabší korelace byla pozorována s parametrem I. Model zohledňující efekt odstínu (H) na obsah chlorofylu měl koeficient determinace (R^2) 0,61. Tento výsledek byl nicméně horší než koeficient determinace pro sytost (S), který byl 0,85 a je tedy vhodnější pro odhad chlorofylu. Bylo zjištěno, že barevný model HSI dosahuje lepšího přizpůsobení než barevný model RGB (Zhang et al. 2022).

Další studie se zabývala obsahem pigmentů u tropických stromů *Cariniana legalis* s *Cariniana estrellensis* a popisuje odhad množství antokyanů v listu. Hlavními pigmenty v listech jsou chlorofyly, karoteny a xantofyly. Chlorofyly absorbují záření v modrém a červeném pásmu VIS, zatímco karoteny a xantofyly absorbují zejména záření v modrém pásmu. Jelikož pouze chlorofyly z těchto 3 zmíněných pigmentů absorbují v červeném pásmu, dalo by se čekat, že vyšší hodnoty obsahu chlorofylu budou odpovídat nižším hodnotám R. Oproti očekávání však u druhu *Cariniana legalis* nebylo s rostoucím množstvím chlorofylu registrováno snížení hodnoty R. *Cariniana estrellensis* toto předpokládané snižování hodnoty R v závislosti na obsahu chlorofylu vykazoval. To lze vysvětlit vyšším obsahem antokyanů v listech *C. legalis* oproti *C. estrellensis* (Mielke et al. 2021).

3.6.6. RGB a heritabilita

RGB obrazová data pro fenotypizaci rostlin mohou sloužit jako levná alternativa oproti multispektrálním a hyperspektrálním záznamům. Indexy odvozené z RGB lze snadno získat ze standardních fotoaparátů a jsou vhodné pro studium morfologických vlastností vegetace. Ve studii zabývající se populacemi borovice halepské (*Pinus halepensis*) byly zkoumány dvě odlišné skupiny RGB indexů. První skupina indexů pracovala s parametrem intenzity z HSI systému. Intenzita, která je indikátorem jasu a z ní odvozené indexy byly spojeny s obsahem chlorofylu v listech. Měřené populace vykazovaly variabilitu obsahu chlorofylu v jehlicích během jara. Toto zjištění bylo podloženo i multispektrálními daty. Druhá skupina indexů ukázala významnou populační variabilitu a konzistentní genetické hodnocení napříč opakovanými měřeními. Většina těchto indexů

souvisí se „zeleností“ obrazových dat a je spojována s plochou listů zemědělských plodin. Výsledky naznačují, že RGB indexy jsou indikátorem populačních rozdílů v počtu jehlic, v jejich celkové ploše nebo v obou faktorech současně (Santini et al. 2019).

3.7. Segmentace

Segmentace je operace, která se zabývá dělením obrazových dat. Základním principem rozdělení obrázků je nalezení disjunktních a homogenních oblastí, nebo ekvivalentně nalezení hran nebo hranic. Tyto oblasti nebo hrany odpovídají skutečným objektům nebo jejich částem v rámci obrazu. Segmentace je tak prvním krokem v mnoha operacích jako je například rozpoznávání a detekce (Lucchese, Mitra 2001)

Velmi obecně lze segmentační přístupy rozdělit na segmentaci založenou na pixelech (pixel-based) a segmentaci založenou na objektech (object-based). Pixel-based segmentace se používá zejména v případě, že jednotlivé pixely odpovídají nebo jsou menší než detekované prvky. Do pixel-based segmentačních metod spadá zejména prahování („*thresholding*“), kdy se posuzuje každý pixel samostatně a na základě jeho hodnoty se zařadí do určité kategorie. Do object-based segmentace spadají složitější metody rozpoznávající jednotlivé objekty. Objekty mohou být rozpoznávány pomocí identifikace hrany (edge-based). Ta je určována jako náhlá změna obrazových vlastností, např. RGB hodnot. Další přístup pracuje na vyhledávání oblastí s podobnými hodnotami pixelů (region-based). Jsou vyhledávány oblasti pixelů, ke kterým jsou na základě podobnosti připojovány další pixely a vzniká tak region určující objekt. Přístup může být ale i opačný. Obraz je rozdělován do regionů na základě podobnosti pixelů, až je rozdělen na jednotlivé objekty. Lze využít i kombinaci. Třetí možností segmentace jsou sémantické metody („*semantic*“). Do sémantických metod patří např. neuronové sítě (*neural networks*“), metoda podpůrných vektorů („*support vector machine*“) nebo konvoluční neuronové sítě s hlubokým učením (Hossain, Chen 2019).

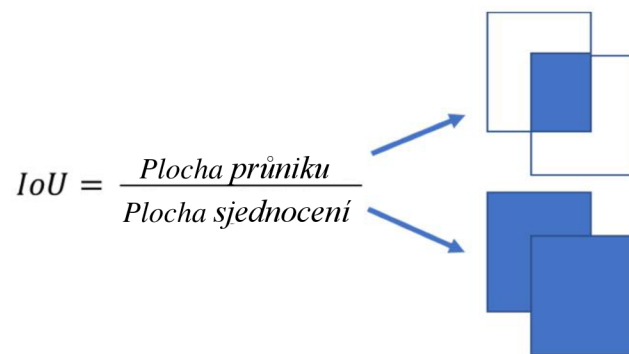
3.7.1. Algoritmus YOLO („You Only Look Once“)

YOLO, také známý jako *You Only Look Once* (podíváš se jen jednou), je algoritmus určený zejména pro detekci objektů v reálném čase. S postupem času a dalšími verzemi tohoto algoritmu se přidaly i další funkce jako např. segmentace instancí objektů („*instance segmentation*“) nebo sémantická segmentace (Terven, Cordova-Esparza 2023) Název You Only Look Once vychází z toho, že narozdíl od předchozích algoritmů pro

detekci objektů prochází obraz svojí neuronovou sítí pouze jednou. Předchozí algoritmy rozdělávaly obraz do více regionů, které postupně zkoumaly a vyhledávaly v nich objekty. YOLO toto zkoumání posouvá na úroveň celého obrázku. Pomocí neuronové sítě predikuje boxy, kdy každý z nich obsahuje detekovaný objekt. Zásadní změnou ale je, že to dělá současně (Redmon et al. 2016).

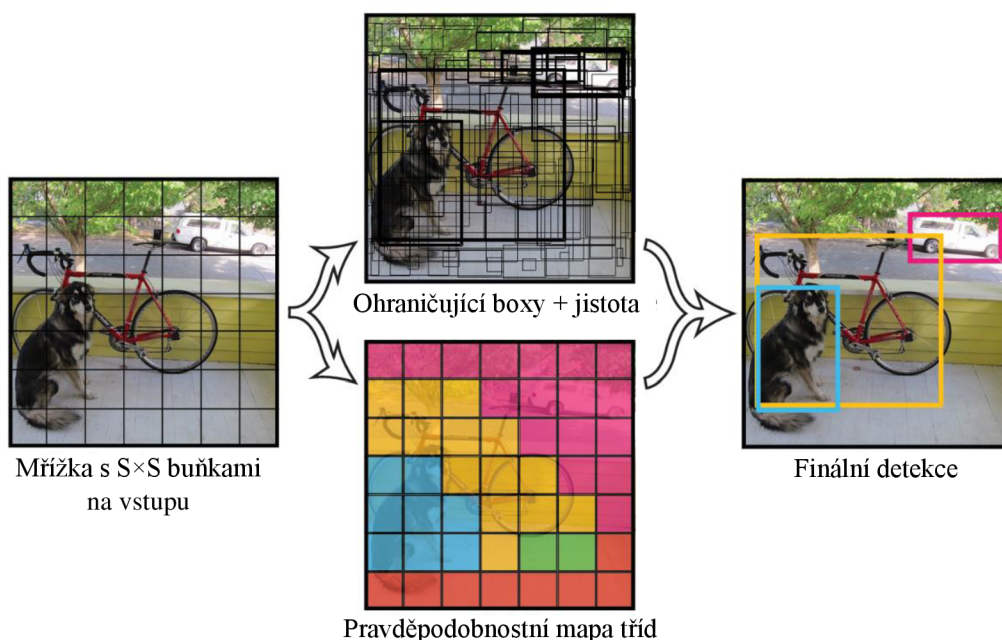
3.7.2. Detekce objektů pomocí YOLO

Detekce objektů funguje na následujícím principu. Obraz je rozdělen do buněk o velikosti 'S'×'S'. Pokud se střed objektu nachází v jedné z těchto buněk, daná buňka má na starost detekci tohoto objektu. Každá buňka v této mřížce je odpovědná za vytvoření určitého počtu 'B' ohraničujících boxů. Všechny tyto boxy obsahují objekt, a také mají přiřazené skóre reprezentující spolehlivost, že box obsahuje objekt a zároveň vypovídající o tom, jak dobře je objekt boxem ohraničen. Pokud se v buňce žádné objekty nenachází, toto skóre by mělo být nula. Pokud v buňce je objekt, skóre bude rovno podílu průniku a sjednocení („*Intersection over Union*“ – IoU) mezi předpovězeným boxem a reálným obrazem. Příklad IoU je uveden na obrázku 12.



Obrázek 12: Schématické vysvětlení IoU. Zdroj: přeloženo dle Paraskevoudis et al. (2020).

Všechny buňky mřížky zároveň předpovídají podmíněné pravděpodobnosti tříd předpovídaných objektů. Tyto pravděpodobnosti jsou podmíněny tím, že buňka mřížky obsahuje objekt. Pro každou buňku je vždy předpovídána pouze jedna sada pravděpodobností tříd, bez ohledu na počet boxů B. Následně jsou násobeny pravděpodobnosti tříd a jednotlivé předpovědi spolehlivosti boxu. Výsledkem je skóre spolehlivosti specifické pro třídu a každý box. Toto skóre kóduje jak pravděpodobnost, že se daná třída objeví v boxu, tak i to, jak dobře předpovězený box ohraničuje objekt (Redmon et al. 2016). Tento princip je schématicky zobrazen na obrázku 13.



Obrázek 13: Schématické zobrazení principu detekce objektů algoritmu YOLO. Zdroj: Redmon et al. (2016).


3.7.3. Segmentace objektů pomocí YOLO

Jak již bylo zmíněno výše, novější verze YOLO dokáží provádět nejen detekci objektů ale i segmentaci. Vzhledem k tomu, že tato práce využívá algoritmus YOLOv7 (v7 označuje verzi algoritmu), bude tato kapitola vztahena zejména k této verzi.


YOLOv7 disponuje algoritmy pro sémantickou segmentaci a segmentaci instancí objektů. Během sémantické segmentace se každému pixelu přiřadí kategorie a poté se pixely z jednotlivých kategorií sloučí dohromady a vytvoří masku na obraze. Pokud by byla na fotografii například dálnice plná aut a byla by prováděna sémantická segmentace objektu auta, budou všechny pixely reprezentující veškerá auta na fotografii přiřazena do stejné kategorie. Segmentace instancí objektů se zabývá detekcí a vymezením každého jednotlivého výskytu objektu na obraze. Detekuje všechny instance v rámci jedné třídy samostatně. Nejprve provede detekci obrazu a všechny detekované obrazy ohraničí boxy. Po nalezení všech boxů v každém z nich použije model sémantické segmentace. Na příkladu s dálnicí by výsledek vypadal tak, že by algoritmus rozeznal všechna auta samostatně, takže by bylo možné odlišit auto 1, auto 2 atd. (Walia 2022). Rozdíl mezi sémantickou segmentací a segmentací instancí objektů je ukázán na obrázku 14.




Rozpoznávání obrazu



Detekce objektů



Sémantická segmentace



Segmentace instancí objektů

Obrázek 14: Rozdíl mezi rozpoznáváním obrazu, detekcí objektů, sémantickou segmentací a segmentací instancí objektů. Zdroj: Lin et al. (2014).

3.7.4. Trénování segmentačního modelu na vlastních datech

Pokud je cílem segmentovat obraz, jsou využívány buď modely pro segmentaci, které již existují nebo je potřeba vytvořit vlastní model, který rozezná a segmentuje požadované objekty. YOLO má vlastní předtrénovaný model, pomocí kterého lze rozeznávat až 80 tříd objektů. Tento model byl natrénovaný na datasetu COCO. COCO je dataset společnosti Microsoft, který obsahuje více než 330 000 obrázků, z nichž více než 200 000 je anotováno. Proto se používá pro vzájemné hodnocení jednotlivých modelů. Tento předtrénovaný model je ale možné vzít a přetrénovat na rozpoznávání vaší žádané třídy, například semenáčků borovice. Pro vytvoření vlastního modelu je nejprve potřeba vytvořit vlastní dataset, na kterém se bude model trénovat. Tento dataset bude tvořen obrázky a k nim připojenými anotacemi. Tyto anotace jsou vlastně jen souřadnice bodů, které udávají hranice objektu na obrázku (Skalski 2022). Ukázka takovéto anotace je na obrázku 15.

Po provedení anotace obrázků může být využita augmentace. Tento proces zahrnuje zvýšení počtu obrázků prostřednictvím modifikace již anotovaného obrázku. Existuje několik metod augmentace, včetně oříznutí nebo otočení obrázku, čímž vzniká zcela nový obrázek vhodný pro trénování modelu. Tento rozšířený dataset slouží k tréninku nového modelu. Pokud je připraven dataset, je možné přistoupit k trénování nového modelu.

Postup zahrnuje použití předchozího modelu a zhodnocení, zda ohraničující box modelu lépe odpovídá IoU. Tento proces se opakuje v několika cyklech, a v každém cyklu je tato metoda testována na více obrázcích. Pokud dojde k vylepšení modelu, je použit v dalším cyklu. Tímto způsobem vzniká model, který je schopen identifikovat i nové třídy objektů. (Skalski 2022).

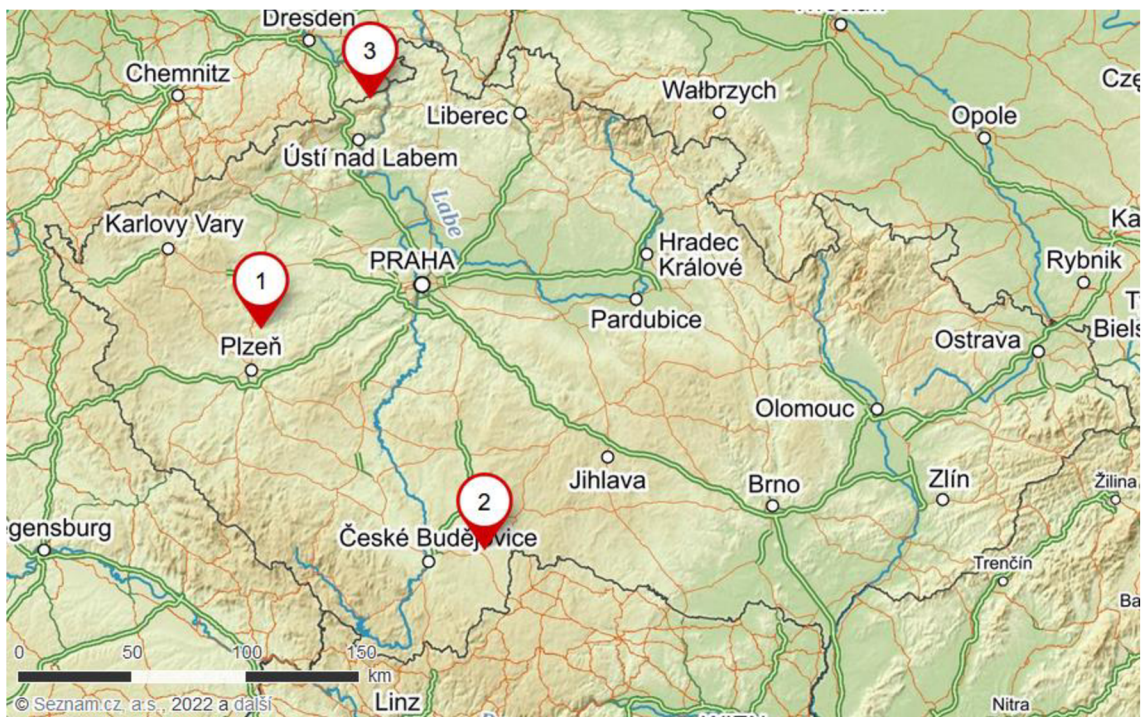


Obrázek 15: Anotovaný semenáček borovice

4. Metodika

4.1. Původ reprodukčního materiálu

Reprodukční materiál, ze kterého byly vypěstovány zkoumané semenáčky borovice lesní, pocházel ze tří semenných sadů borovice lesní. Jednalo se o semenné sady z lesních správ Plasy, Třeboň a Děčín. Umístění těchto semenných sadů je vyznačeno na obrázku 16. Všeobecné informace o plochách původu jsou uvedeny v tabulce 2. Meteorologická jsou zjišťována pro semenný sad LS Plasy ze stanice Kralovice (Plzeňský kraj, 449 m n. m.), pro semenný sad LS Třeboň ze stanice Třeboň (Jihočeský kraj, 428 m n. m.) a pro semenný sad LS Děčín ze stanice Sněžník (Ústecký kraj, 569 m n. m.). Zmíněné meteorologické stanice jsou vždy nejbližší k jednotlivým sadům. Nicméně neposkytují informace o průměrné době trvání slunečního svitu. Pro ty byla použita data ze stanic Plzeň – Bolevec (Plzeňský kraj, 331 m n. m.) pro Plasy, pro Třeboň data ze stanice Jindřichův Hradec, Děbolín (Jihočeský kraj, 524 m n. m.) a pro Děčín data ze stanice Ústí nad Labem, Kočkov (Ústecký kraj, 375,39 m n. m.). Hodnoty v tabulce odpovídají průměrům za posledních 20 let.



Obrázek 16: Poloha vybraných semenných sadů na mapě České republiky. 1 – lokalita Plasy; 2 – lokalita Třeboň 3 – lokalita Děčín. Zdroj mapového podkladu: Seznam.cz (2022).

Semenný sad	LS Plasy	LS Třeboň	LS Děčín
Evidenční číslo	79	82	165
Místní název	Doubrava	Holičkovna	Hrádek
GPS (WGS-84)	49°54'31.343"N, 13°26'33.360"E	49°0'59.950"N, 14°49'28.821"E	50°49'8.696"N, 14°7'2.199"E
PLO	6	15b	19
SLT	3 I	0 K	5 K
LVS	2 – bukodubový	3 – dubobukový	5 – jedlobukový
Nadmořská výška [m n. m.]	385	430	465
Průměrný měsíční úhrn srážek [mm]	41,9	53,8	69,5
Průměrná denní teplota [°C]	8,9	8,8	7,5
Průměrná doba trvání slunečního svitu v roce [h]	1515,6	1736,8	1590,4

Tabulka 2: Všeobecné údaje o semenných sadech. Zdroj: vytvořeno z dat ČHMÚ (2022), Seznam.cz (2022) a Svoboda et al. (2010).

4.2. Podmínky pěstování semenáčků

Semena byla vyseta a po celou dobu pěstována v arboretu Sofronka v Plzni–Bolevci. Sofronka byla založena v roce 1956 Ing. Karlem Kaňákem CSc. jako pracoviště VÚLHM. Inženýr Kaňák zde založil sbírku druhů rodu *Pinus* z celého světa. VÚLHM toto pracoviště v roce 2009 zrušil a Sofronka přešla pod Správu veřejného statku města Plzně (Kaňák 2016).

Pozemek leží na souřadnicích 49°47'21" N, 13°23'9" E (WGS-84). Je mírně svažité s jižní expozicí s nadmořskou výškou 330–350 m n. m. Arboretum se nachází v bukodubovém lesním vegetačním stupni. Borovice byly pěstovány v sadbovačích s 60 buňkami (6 řad a 10 sloupců). Substrát, ve kterém byly semenáčky pěstovány, byl stejný ve všech sadbovačích. V každém sadbovači se nacházely pouze semenáčky z jednoho semenného sadu. Uspořádání sadbovačů v prostoru, a tedy rozmístění populací v prostoru je uvedené v příloze 1. Vybrané průměrné meteorologické hodnoty z arboreta za posledních 20 let jsou uvedeny v tabulce 3.

Průměrná denní teplota [°C]	8,5
Průměrný měsíční úhrn srážek [mm]	44,3
Průměrný roční úhrn srážek [mm]	531,9
Průměrná doba trvání slunečního svitu v měsíci [h]	121,5
Průměrná doba trvání slunečního svitu v roce [h]	1457,6

Tabulka 3: Vybraná meteorologická data ze stanice Plzeň–Bolevec. Zdroj: ČHMÚ (2022).

4.3. Terénní měření

4.3.1. Měření spektrometrem s optickým kabelem

Měření probíhalo 9. a 10. září 2021 na konci vegetační sezóny v arboretu Sofronka. Byly měřeny jednoleté semenáčky borovice lesní, jejichž semena pocházela ze 3 semenných sadů. Vzhledem k tomu, že byl znám pouze mateřský strom, ze kterého se osivo v semenném sadu sbíralo, jednalo se o polosesterská potomstvo. Bylo měřeno 746 semenáčků původem z Plas, 750 semenáčků původem z Třeboně a 292 semenáčků původem z Děčína. Celkem bylo změřeno 1788 jedinců.

Semenáčky byly měřeny spektrometrem FieldSpec® 3. Ten umožňuje měřit záření, ozáření, reflektanci a transmitanci. Měřené spektrum má rozpětí 350–2500 nm. Potřebnými součástmi vybavení byly ovladač spektrometru – přenosný laptop se softwarem RS³ a optický kabel. Při měření pouze optickým kabelem chybí vlastní zdroj světla a místo něj je využito sluneční záření. Tato metoda je tedy velmi závislá na počasí. Aby mohl být vliv počasí odstraněn, každých 10 měření se prováděla normalizace vzhledem k bílé referenci – téměř 100% odrazivému materiálu (ASD Inc. 2010). Na kmínky měřených semenáčků byla nasazována šablona z černého papíru, aby se odstranil vliv odrazivosti substrátu pod stromky. Optický kabel se namířil ze shora na semenáček tak, aby mířil na terminální pupen. Vzdálenost kabelu od semenáčku odpovídala přibližně 5 cm. Úhel, ze kterého optický kabel zachytával odražené paprsky, byl 5°, aby co nejvíce zachyceného záření udávalo reflektanci semenáčku. Počet snímků spektrometru pro vytvoření průměrného spektra každého semenáčku byl nastaven na 50. Když se hodnoty viditelné na laptopu ustálily, byly změřené hodnoty reflektance uloženy.

Aby výsledky potomstev a populací nebyly ovlivněny stejným časem měření, sadbovače z různých sadů byly měřeny střídavě. Pořadí měřených sadbovačů a systém měření semenáčků v sadbovači je uveden v příloze 2.

4.3.2. Pořízení fotografií

Pořízení fotografií proběhlo ve třech různých dnech v rámci 3 různých období. Poprvé byly sadbovače foceny 10. 9. 2021. Druhý termín focení byl dne 23. 10. 2021. Třetí focení proběhlo dne 22. 1. 2023. Fotografování sadbovačů probíhalo vždy mezi 14:30–15:30 ve stejném pořadí jako jejich měření spektrometrem. Sadbovače byly fotografovány bez přestávek, aby se okolní podmínky změnily co nejméně. Fotografie byly pořízeny fotoaparátem Canon EOS 1200D a byly uloženy ve formátu DNG, který pořízené fotografie nekomprimuje. V rámci každého focení bylo použité jiné nastavení fotoaparátu, aby byly fotografie co nejkvalitnější.

4.4. Získání RGB dat z fotografií.

Pro získání průměrných RGB hodnot z každého semenáčku je třeba provést sérii na sebe navazujících kroků, které budou popsány dále. Kódy použité pro jednotlivé kroky a další algoritmy, které jsou popsány v této kapitole jsou vytvořené v různých programovacích jazycích a jsou dostupné na serveru GitHub (<https://github.com/>) na následující adrese: https://github.com/jirkachuchl/pine-seedling_segmentation.git.

4.4.1. Standardizace dat pomocí bílé reference

První krok v postupu zpracování fotografií bylo využití bílé reference pro standardizaci fotografií. Aby byly obrázky porovnatelné, je vhodné co nejvíce omezit proměnlivé vnější vlivy jako je například změna osvětlení v důsledku zastínění mrakem nebo různá denní doba času focení, a tedy i úhel dopadu slunečních paprsků. Jako bílá reference byly využity popisky z kancelářského papíru přiložené vedle zaznamenávaných sadbovačů na každé fotografii. Standardizace byla prováděna v softwaru FIJI (Schindelin et al. 2012). Každá fotografie byla rozdělena na jednotlivé barevné kanály – R, G a B. V každém kanálu byla vybrána oblast bílého papíru – bílé plochy, u které se předpokládá, že její RGB hodnota bude 255, 255, 255. Pro barevný kanál byl změřen průměr za vyznačenou plochu bílého papíru. V ideálním případě by byla průměrná hodnota 255, nicméně kvůli okolním vlivům byla tato hodnota jiná. Aby byl stav co nejvíce univerzálně porovnatelný, vydělila se hodnota 255 reálným průměrem zjištěným z bílého papíru v daném kanálu. Pokud by byla reference z papíru ze 100% bílá, výsledkem by byla


hodnota 1, vlivem různých světelných podmínek bude hodnota daného kanálu typicky menší než 255 a výsledkem bude číslo nižší než 1. Tímto podílem se vynásobí každý pixel obrázku v daném kanálu. Tento úkon se provedl pro všechny 3 kanály a ty se poté opět spojily do RGB obrázku. Takto upravený obrázek by měl být porovnatelný s ostatními, jelikož se standardizoval na stejnou úroveň. Pro tento proces bylo vytvořeno makro.

4.4.2. Transformace obrázku

Dalším krokem byla transformace obrázku tak, aby měly sadbovače tvar obdélníků (jejich tvar na fotografiích se od obdélníkového tvaru vždy mírně odlišoval). Nejprve bylo potřeba uložit souřadnice pixelů rohů jednotlivých sadbovačů. Toho bylo dosaženo vlastní funkcí v jazyce Python, verze 3.12 (Van Rossum, Drake 2009). Tyto souřadnice byly v dalším kroku využity pro transformaci obrázku opět pomocí kódu v Pythonu. Tím bylo dosaženo odstranění různých náklonů a pootočení fotoaparátu při pořizování fotografií. Tato transformace byla nutná, aby bylo později možné sadbovač pravidelně rozdělit na jednotlivé buňky a aby tak bylo možné identifikovat jednotlivé stromky samostatně. Během transformace zároveň došlo k oříznutí obrázku. Okraje byly ponechány pouze 400 pixelů (odpovídající zhruba 5 cm) od spojnice vyznačených rohů sadbovače tvořící hranu sadbovače.

4.4.3. Rozřezání obrázku

Po transformaci bylo nutné jednotlivé obrázky rozřezat na části o velikosti 600×600 pixelů. Upravený segmentační model YOLOv7, který byl použit pro segmentaci borovic má omezenou velikost vstupních obrázků, kterou dokáže zpracovat. Při použití větších obrázků by byl nejdříve obrázek zmenšen a tím by byla výrazně snížena i jeho kvalita a segmentace by se nemusela podařit nebo by byla významně horší (Wang et al. 2023). Rozřezání obrázků na části bylo provedeno vlastní funkcí v jazyce R, verze 4.2.2. (R Core Team 2023). Každý obrázek byl rozřezán v pěti různých variantách. První rozřezání začalo na souřadnicích pixelů [0,0]. Další řezy byly posunuty o 200 nebo 400 pixelů doprava nebo dolů. Rozřezání s posunem o 400 pixelů dolů je schematicky naznačeno na obrázku 17. Toto vícenásobné rozřezání bylo použito ze dvou důvodů. Je možné, že na posunutém výřezu bude segmentace provedena precizněji a zároveň více překrývajících se výřezů při následném spojení do celku vytvoří lepší přechody mezi jednotlivými částmi.



Obrázek 17: Schématická ukázka rozežrání obrázku s odsazením 400 pixelů dolů

4.4.4. Vytvoření segmentačního modelu

Pro segmentaci borovic byl použit lehce upravený segmentační model YOLOv7. Anotace trénovacích dat, na kterých byl model vytvořen, proběhla v online aplikaci Roboflow (<https://roboflow.com>). Zde byla také provedena augmentace, tedy zvětšení objemu trénovacích dat pomocí drobných úprav obrázků (pootočení, převrácení...) a vytvoření více poupravených kopií, na kterých se bude model trénovat. Model byl tedy ve výsledku trénován na 1081 obrázcích, z čehož 996 obrázků byl trénovací dataset a 85 obrázků byl validační dataset.

Trénování segmentačního modelu a samotná segmentace proběhla pomocí kódu v jazyce Python v prostředí Google Colab (<https://colab.research.google.com>). Google Colab je prostředí, které umožňuje psát a spouštět skripty v jazyce Python a umožňuje přístup na výkonné grafické karty. Zde byl pomocí algoritmu YOLOv7 natrénován segmentační model a proběhla samotná segmentace jednotlivých částí obrázku.

4.4.5. Segmentace pomocí YOLOv7

Pro segmentaci byl použit lehce upravený algoritmus YOLOv7. Drobné úpravy spočívaly v tom, že oproti původnímu algoritmu byly z výsledného obrázku s maskou odstraněny názvy segmentovaných tříd, jelikož se vždy jednalo o jedinou segmentovanou třídu – tedy oblast semenáčku (označováno jako „*pine-seedling*“). Dále bylo vypnuto zobrazování tzv. bounding boxu, což je obdélník, který ohraničuje plochu, ve které se segmentovaný prvek nacházel a společně s ním byla uváděna informace o procentuální jistotě toho, že se jedná o správně segmentovaný objekt. Finálně byla nastavena maska vytvořená algoritmem na neprůhlednou červenou, jejíž RGB hodnoty jsou $R = 255$, $G = 56$, $B = 56$. Po těchto úpravách byl použit natrénovaný model k segmentaci jednotlivých výřezů obrázků. Výsledek segmentace je vidět na obrázku 18.

4.4.6. Odstranění pozadí segmentovaných jehlic

Po segmentaci bylo nutné odstranit pozadí. To bylo znovu provedeno vlastní funkcí v jazyce Python. Princip odstranění pozadí spočíval v porovnání původní části obrázku bez vytvořené masky a segmentované části obrázku s vytvořenou maskou. Algoritmus porovnával jednotlivé pixely na obrázku s maskou a v případě, že měl pixel hodnotu červené masky ($R = 255, G = 56, B = 56$), ponechal na druhém obrázku pixelu na stejné souřadnici jeho barvu. V případě, že měl pixel na obrázku s maskou jinou hodnotu, než je hodnota červené masky, nahradil hodnotu pixelu stejné souřadnice na druhém obrázku pixelem černé barvy ($R = 0, G = 0, B = 0$). Po porovnání každého pixelu na obrázku, zůstala původní barva pouze pixelům „schovaným“ pod maskou a ostatní byly změněny na černé. Tento proces se provedl u každé vyříznuté části obrázku a výsledkem byly segmentované borovice na černém pozadí. Jedna z výsledných částí s odebraným pozadím je zobrazena na obrázku 18.



Obrázek 18: Část fotografie před a po segmentaci upraveným algoritmem YOLOv7 a výsledek po odstranění pozadí.

4.4.7. Spojení částí do celého obrázku

Po odstranění pozadí byly jednotlivé části spojeny do celého obrázku. Jednotlivé části měly zachované pojmenování, kde na prvním místě byla informace, o jaký sadbovač se jedná. Na druhém místě byla informace, zda se jedná o obrázek s výřezy začínajícími souřadnicemi pixelů $[0,0]$ nebo výřezy posunuté. Na třetím místě figurovala informace o řádku, ze kterého výřez pocházel a na čtvrtém místě se nacházela informace o sloupci. Název výřezu *1_400_down_4_7.png* tedy odkazoval na to, že se jedná o sadbovač č. 1, výřezy se začaly tvořit s posunutím o 400 pixelů dolů a bez posunutí doprava a že se jedná o výřez ve 4. řadě a v 7. sloupci. Toto označení zajistilo správné seřazení jednotlivých výřezů, které byly následně pomocí jazyka Python spojeny do jednoho výstupu. Pro každý sadbovač se tedy vytvořilo 5 výstupů. Spojení výřezů, které nebyly nijak odsazeny od začátku obrázku, vytvořilo první výstup. Druhý a třetí výstup byl tvořen spojením

výřezů odsazených o 200 nebo 400 pixelů doprava. Čtvrtý a pátý výstup tvořilo spojení výřezů odsazených o 200 nebo 400 pixelů dolů. Příklad jednoho z výstupů je viditelný na obrázku 19.



Obrázek 19: Výstup po spojení jednotlivých vyříznutých částí

4.4.8. Překryv jednotlivých výstupů

Aby byly přechody mezi jednotlivými výřezy ve spojeném obrázku plynulé a aby se případně podařilo segmentovat i napoprvé nesegmentované části borovic, byly pro každý sadbovač segmentovány i obrázky s posunem 200 a 400 pixelů dolů nebo doprava. Sjednocením těchto výstupů byl získán finální obrázek s plynulými přechody a vysegmentovanými jehlicemi, které se napoprvé nepovedlo segmentovat. Pro sjednocení byl použit kód v Pythonu. Každému obrázku se zadal počátek, ve kterém se začaly vytvářet jednotlivé výřezy. Takto překrývajícím obrázkům se poté porovnávaly jejich pixely. Pokud byl pixel na jakémkoli obrázku jiný než černý, nechala se jeho barva. Pokud byl daný pixel na všech obrázcích černý, zůstal černý i na výsledném obrázku. Tímto způsobem byly výstupy sjednoceny do finálního výstupu pro každý sadbovač. Příklad takto sjednoceného finálního výstupu lze vidět na obrázku 20.




Obrázek 20: Sjednocení jednotlivých výstupů do finálního obrázku

4.4.9. Identifikace jednotlivých stromků a získání RGB hodnot

Pro statistickou analýzu barev bylo potřeba z obrázků získat informace o průměrné barvě jednotlivých stromků. K tomu byl použit kód napsaný v jazyce Python. Je potřeba si uvědomit, že finální výstup ze segmentace je vlastě transformovaný obrázek s odebraným pozadím. Aby byl každý semenáček správně identifikován, bylo potřeba ho přiřadit do správné buňky sadbovače. Na transformovaném obrázku sadbovače s neodstraněným pozadím byly vybrány 2 diagonální rohy sadbovače, které definovaly obvod sadbovače, tedy obdélník. Každý sadbovač měl 10 sloupců a 6 řad. Podílem vzdálenosti 2 rohů na delší straně a počtem sloupců byl získán jeden rozměr buňky a podílem vzdálenosti 2 rohů na kratší straně a počtem řad byl získán druhý rozměr buňky. Takto vytvořená imaginární síť vymezila prostor každé buňky. Pomocí skriptu v jazyce Python byly zjištěny souřadnice terminálních pupenů každé borovice přítomné na obrázku. Bylo otevřeno interaktivní okno, které při kliknutí na terminální pupen zapsalo jeho souřadnice. Porovnáním souřadnice terminálního pupenu a souřadnic náležejících každé buňce bylo každé borovici přiřazeno identifikační číslo.

Pro každý semenáček se zjišťovala průměrná RGB hodnota. Na základě rozměrů buňky sadbovače se určil podle kratší strany buňky poloměr, který kolem bodu v každém terminálním pupenu vytvořil imaginární kruh, ze kterého byla RGB hodnota zjišťována. Pokud se v ploše, ze které byla průměrná hodnota RGB zjišťována, vyskytoval černý pixel, byl z vyhodnocování odebrán. V potaz byly brány pouze barevné pixely, tedy ty,

kteře reprezentovaly jehlice nebo pupeny stromků. Tato data byla přiřazena k jednotlivým identifikovaným stromkům a byla zapsána do tabulky. Tato tabulka byla poté napárována na tabulku s hyperspektrálními daty, tak, že pro každou měřenou borovici byly uloženy RGB hodnoty a hyperspektrální data. Schématické zobrazení zjišťování průměrných RGB hodnot je zobrazeno na obrázku 21.



Obrázek 21: Schématické zobrazení identifikace a zjišťování průměrných RGB hodnot. Plná červená čára vyznačuje okraj sadbovače, červené přerušované čáry vyznačují okraje jednotlivých buněk, červené tečky vyznačují označené terminální pupeny a modré kruhy vyznačují oblast, ze které byla pro každý stromek zjišťována průměrná RGB hodnota.

4.5. Genomická data

V rámci souběžně prováděné studie, která byla prováděna na stejných semenáčcích využitých v této práci, byla pro některé z měřených semenáčků provedena DNA analýza. U 790 jedinců byla extrahována genomová DNA, která byla použita k identifikaci tzv. SNP („Single Nucleotide Polymorphism“). Tyto SNPs prošly kvalitou kontroly a vybraná část byla použita ke konstrukci G matice. Tato matice byla převzata a napojena na stávající data, pro zpřesnění modelů odhadujících heritabilitu v užším smyslu – h^2 .

4.6. Výpočet RGB a HSV hodnot ze spektrální křivky

Pro následnou statistickou analýzu bylo potřeba získat hodnoty RGB a HSV ze změřených spektrálních křivek. Kalkulace hodnot proběhla v prostředí jazyka R a jeho datových balíčků colorscience a colorspace. Postup, který tyto balíčky využívají, je shodný s postupem popsáním v kapitole 3.6.2. Pro každý semenáček byly ze změřené reflektance spočteny RGB hodnoty. Ty byly poté použity pro převod na HSV hodnoty.

4.7. Statistická analýza dat

Získaná data byla zpracována a vyhodnocena pomocí popisné a matematické statistiky. K analýze byl použit Waldův test (modifikovaný F-test, který je součástí hodnocení ASReml), korelační koeficient, analýza hlavních komponent (PCA) a částečná regrese nejmenších čtverců (PLSR). Pro statistickou analýzu bylo využito prostředí jazyka R (verze 4.2.2) a jeho datové balíčky ASReml-R, pls, stats, a circular. Pomocí těchto a základních R balíčků byly také vytvořeny použité grafy. Pro některé grafické výstupy byl použit jazyk Python. K práci v prostředí jazyka R bylo využito ide RStudio.

4.7.1. Cirkulární data

Hodnota odstínu („*hue*“) v systému HSV je cirkulární povahy. Jedná se o orientovaná data, jsou tedy určena úhlem od 0° do 360° , na který poté opět navazuje 0° . Proto se pro analýzy s ním využívá cirkulární statistika (Hanbury 2003).

Pro výpočet průměrných odstínů a základních statistik byl použit balíček circular v prostředí jazyka R. Ve složitějších regresních modelech v existujících balíčcích jazyka R není možné cirkulární data použít, je tedy nutná jejich transformace. Pro účely této práce stačí, aby rozsah dat nepřekračoval hraniční hodnotu 360° . Je-li rozsah změřených dat mezi úhly například 100° – 300° , výsledky klasické a cirkulární statistiky budou srovnatelné. Je-li rozsah změřených dat mezi úhly například 240° – 50° , výsledky srovnatelné nebudou. Tento princip je zobrazen v příloze 3. Transformaci dat lze provést prostým přičtením konstanty tak, aby data ležela v intervalu mezi 0° a 360° . Poté lze tato transformovaná data použít bez získání chybných výsledků.

4.7.2. Analýza hlavních komponent – PCA

Analýza hlavních komponent („*principal component analysis*“ – PCA) je využívána k redukci rozměrů nebo k odstranění korelace dat. Cílem je snížení počtu proměnných, ale zároveň zachování původní informace v co největší míře. Vybírají se tedy proměnné, které informaci ovlivňují nejvíce. Data upravená tímto způsobem se lépe analyzují, snížení počtu proměnných však vždy ubírá na přesnosti dat (Jaadi 2021). Hlavní komponenty tvoří osy, podél kterých je rozptyl dat největší. Osa x je tvořena vektorem, podél kterého je největší rozptyl. Osa y a další následné osy jsou tvořeny vektorem kolmým na osu x. Data jsou zároveň natočena tak, aby i rozptyl podél dalších os byl co největší. Tyto osy prochází těžištěm dat. Tento proces nijak nezmění prostorové vztahy, ale zároveň jsou tyto nové osy nekorelované. U dat s velkým množstvím

proměnných je možné osy s malým rozptylem ignorovat. Tímto způsobem se sníží počet dimenzí. Výsledkem může být pouze několik smysluplných os – hlavních komponent (Holland 2019).

Analýza hlavních komponent byla použita pro dvourozměrnému zobrazení rozdílů v barvách mezi obdobími i mezi populacemi borovice lesní. Analýza byla provedena v prostředí jazyka R.

4.7.3. Korelační koeficient

Korelační koeficient ukazuje sílu lineárního vztahu mezi dvěma proměnnými. Nabývá hodnoty mezi -1 a 1. Tyto okrajové hodnoty znamenají hodnoty znamenají naprosto lineární vztah mezi proměnnými. Hodnota -1 znamená negativní, klesající vztah, hodnota 1 znamená vztah pozitivní, stoupající, nicméně obě hodnoty jsou maximálně korelovány. 0 znamená, že mezi hodnotami se nenachází žádný lineární vztah (Dodge 2008).

Výpočet Pearsonova korelačního koeficientu je uveden v rovnici 17.

$$Kor(X, Y) = \frac{\sum(x - \bar{x})(y - \bar{y})}{\sqrt{\sum(x - \bar{x})^2 \sum(y - \bar{y})^2}} \quad (17)$$

Pro zjištění lineární závislosti mezi barvami získanými ze segmentovaných fotografií a barvami spočtenými ze spektrálních dat byl použit Pearsonův korelační koeficient. Korelační koeficient byl spočítán v prostředí jazyka R. U cirkulárních dat byla použita obdoba Pearsonova korelačního koeficientu pro cirkulární data z balíčku *circular*.

4.7.4. Částečná regrese nejmenších čtverců – PLSR

Částečná regrese nejmenších čtverců („*partial least square regression*“ – PLSR) je statistická technika, která kombinuje vlastnosti mnohonásobné lineární regrese a analýzy hlavních komponent (PCA) a zobecňuje je. Používá se k predikci množiny závislých proměnných z množiny nezávislých proměnných (prediktorů). Při použití samostatné PCA vyvstává problém, kolik použít komponent k predikci. Zároveň tyto komponenty popisují spíše prediktory, a ne predikovanou množinu. Naproti tomu PLSR nachází prediktory, které jsou relevantní i pro predikovanou množinu. Konkrétně, PLSR hledá komponenty podobně jako PCA, ale navíc musí tyto komponenty co nejvíce vysvětlovat kovarianci mezi množinou závislých proměnných a množinou prediktorů. Jedná se zde o zobecněnou PCA. Na tu navazuje regrese, kde se pomocí vybraných prediktorů predikují hodnoty množiny závislých proměnných (Abdi 2010).

PLSR byla použita pro predikci průměrné barvy semenáčků z hyperspektrálních křivek. Zároveň byla využita k identifikaci nejdůležitějších vlnových délek, které se v rámci měřeného spektra podílejí na tvorbě barvy semenáčku. PLSR byla provedena prostředí jazyka R pomocí balíčku pls. Velikost trénovací sady byla 90 % z celkového počtu, velikost testovací sady byla 10 %.

4.7.5. Smíšené lineární modely

Smíšené lineární modely mohou být vhodným nástrojem pro analýzu dat ze zemědělských, biologických, medicínských nebo environmentálních studií. Tyto modely zahrnují jak fixní, tak náhodné efekty. Fixní efekty jsou zpracovávány na principu, který využívá analýzu rozptylu. Interpretace je shodná. Signifikance rozdílů v rámci fixního efektu se posuzuje pomocí Waldova testu, což je modifikovaný F-test (Gilmour et al. 2009).

ASReml je statistický software a balíček prostředí jazyka R, který využívá smíšené lineární modely. Tyto modely používají metodu maximální věrohodnosti („*residual maximum likelihood*“ – REML) pro dekompozici rozptylu (Butler et al. 2017).

Pomocí ASReml byla v prostředí jazyka R spočtena významnost rozdílů mezi populacemi semenáčků borovice, jako fixní efekt na základě jejich barev. Jako náhodný efekt byla použita G-matice. Díky tomu byla odhadnuta h^2 parametrů, jako poměr variability vysvětlené G-maticí a celkovou variabilitou parametru (V_g/V_p). Signifikance h^2 byla ověřena pomocí „*likelihood-ratio*“ testu (LR test). Tento test ověřuje shodu dvou statistických modelů, pokud se nebude lišit model se zavedeným náhodným efektem G matice a bez náhodného efektu G matice, heritabilita není signifikantní.


Mnohonásobné porovnání bylo realizováno pomocí balíčku asremPlus. Jednalo se o specifickou formu *post hoc* testu, kdy jsou p-hodnoty počítány na základě plovoucí hodnoty Least Significant Difference (LSD).

5. Výsledky


5.1. Segmentace semenáčků borovic

Z původního počtu 1788 semenáčků bylo segmentováno ze zářijových fotografií 1787 semenáčků, z říjnových fotografií 1786 semenáčků a z lednových fotografií 1785 semenáčků. Obrázek 22 ukazuje průměrné barvy semenáčků v průběhu období. V případě, že je místo prázdné, semenáček v buňce sadbovače chyběl nebo nebyl segmentován.


A) Průměrné barvy semenáčků na začátku září



B) Průměrné barvy semenáčků v průběhu října



C) Průměrné barvy semenáčků v průběhu ledna

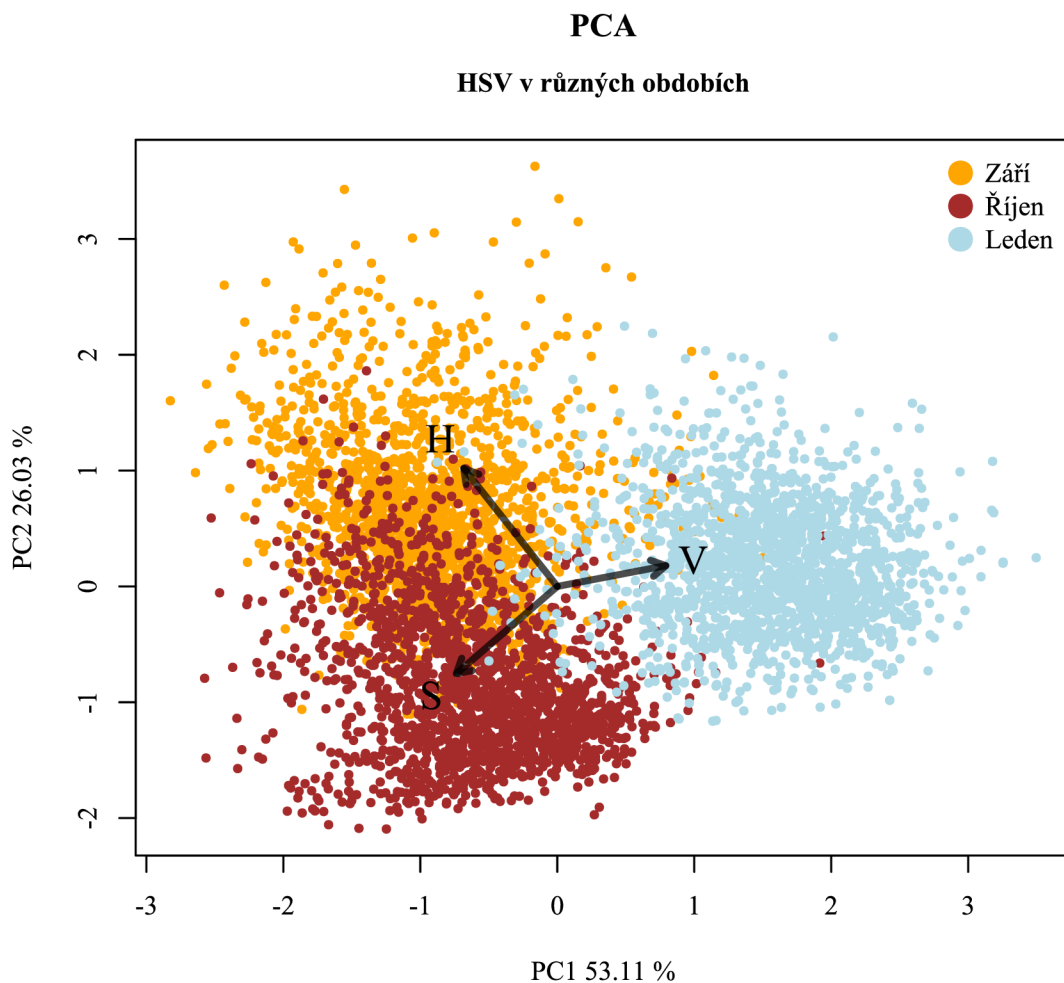


Obrázek 22: Průměrné barvy semenáčků v různých obdobích. A) Průměrná barva semenáčků focených 10. 9. 2021, B) Průměrná barva semenáčků focených 23. 10. 2021, C) Průměrná barva semenáčků focených 22. 1. 2022.

5.2. Fenologie – změna barvy v různých obdobích

5.2.1. Fenologie – změna parametrů barevného systému HSV v různých obdobích

V rámci fenologie byla zkoumána změna barvy jehlic. Analýza hlavních komponent na obrázku 23 ukazuje rozdíly v barvě (HSV) mezi jednotlivými obdobími. Je patrné, že se jednotlivá období odlišují. Zářijové a říjnové hodnoty jasu jsou poměrně srovnatelné. Tyto dvě období se liší zejména hodnotami odstínu a sytosti. Lednové hodnoty HSV se od ostatních odlišují nejvýrazněji, a to ve všech 3 parametrech. Histogramy hodnot odstínu, sytosti a jasu v různých obdobích jsou uvedeny v příloze 4.




Obrázek 23: Analýza hlavních komponent pro HSV hodnoty barev v různých obdobích.

Rozdíly mezi populacemi jsou zobrazeny v barevném kole na obrázku 24. Jednotlivými barvami jsou odlišeny populace, tvary znaků odlišují měřená období. Úhel kruhu 0° – 360° udává odstín barvy, vzdálenost od středu kruhu udává sytost barvy. Barvy ve středu jsou tedy plně achromatické – bílé, barvy na okraji kruhu jsou 100% syté. Pomocná šedá kružnice vyznačuje sytost 50 % v rámci celého barevného kola.

V barevném kole je vidět, že se borovice liší v odstínu dle období. Zářijové odstíny odpovídají světle zelené až žluté barvě, říjnové odstíny odpovídají hnědo-oranžové barvě a odstíny lednového měření odpovídají oranžovo-červené barvě. Sytost je u zářijového a říjnového měření poměrně shodná. U lednového měření sytost výrazně klesá. V září i říjnu vykazuje děčínská populace větší odlišnost oproti zbylým dvěma populacím. Sytost děčínské populace je zde vždy nižší a odstín je vždy o něco vyšší. Plaská i třeboňská populace naopak leží na podobném odstínu a jejich sytost je také poměrně shodná. V lednu se sytost ani odstín u všech tří populací téměř neliší.


Barevné kolo se zobrazenými průměry odstínu a sytosti pro jednotlivé populace v různých obdobích



Obrázek 244: Barevné kolo s průměrnými hodnotami odstínu a sytosti dle jednotlivých populací a období. Úhel od 0°–360° určuje odstín. Vzdálenost od středu ke kraji určuje procento sytosti. Pomocná šedá kružnice vyznačuje sytost 50 % v rámci celého barevného kola. Barva ve středu kruhu je bílá, barva na okraji kruhu je plně sytá. Barvy znaků rozlišují jednotlivé populace, tvary znaků rozlišují jednotlivá období.

5.2.2. Fenologie – změna parametrů barevného systému RGB v různých obdobích

Analýza hlavních komponent na obrázku 25 ukazuje rozdíly v barvě (RGB) jehlic mezi jednotlivými obdobími. Z obrázku je patrné, že se zářijové barvy odlišují poměrem zeleného kanálu. Říjnové a lednové barvy jsou v poměru zeleného kanálu srovnatelné, nicméně lednové barvy se od říjnových liší změnou poměru modrého a červeného kanálu RGB. Histogramy hodnot R, G a B v různých obdobích jsou uvedeny v příloze 5.



Obrázek 255: Analýza hlavních komponent pro RGB hodnoty barev v různých obdobích.

5.3. Korelace barev získaných segmentací a barev získaných z hyperspektrálních dat

5.3.1. Korelace barev ze segmentace a barev vypočtených z hyperspektrálních dat pomocí kolorimetrických funkcí

Pro zjištění vzájemného vztahu mezi barvami získanými segmentací fotografií a barvami spočtenými z hyperspektrálních dat byla spočtena korelace. Výsledné hodnoty korelačního koeficientu jsou uvedeny v tabulce 4. Pro hodnoty sytosti, jasu, a RGB byl

použit Pearsonův korelační koeficient, pro výpočet korelačního koeficientu odstínu byla použita alternativa pro cirkulární data. Nejsilnější korelaci vykazuje odstín z HSV systému, nejslabší korelaci vykazuje modrý kanál z RGB systému.

Parametry barevného systému	Korelační koeficient
Odstín („hue“)	0,519
Sytost („saturation“)	0,239
Jas („value“)	0,207
Kanál R („red“)	0,442
Kanál G („green“)	0,188
Kanál B („blue“)	0,012

Tabulka 4: Hodnoty korelačního koeficientu pro jednotlivé parametry barevných systémů HSV a RGB.

5.3.2. Korelace barev ze segmentace a barev predikovaných z hyperspektrálních dat pomocí modelů PLSR

Pomocí PLSR byl zároveň vytvořeny modely, jejichž cílem bylo na základě spektrálních dat predikovat hodnoty RGB a HSV z dané spektrální křivky. Koeficient determinace (R^2) modelů pro jednotlivé parametry barevných systémů a následná korelace predikované barvy a segmentované barvy jsou uvedeny v tabulce 5. Nejlépe byla variabilita proměnných vysvětlena modelem pro odstín. Koeficient determinace zde dosahuje necelých 60 %. Nejhorších výsledků dosáhl model pro zelenou složku světla v systému RGB. Grafy, které zobrazují importanci jednotlivých vlnových délek pro 1. komponenty PLSR, jsou uvedeny v příloze 6.

Parametry barevného systému	R^2	Korelační koeficient
Odstín	0.597	0.773
Sytost	0.454	0.674
Jas	0.243	0.493
Kanál R	0.436	0,660
Kanál G	0.217	0,466
Kanál B	0.300	0,578

Tabulka 5: Hodnoty koeficientu determinace (R^2) modelů PLSR pro parametry barevných systémů HSV a RGB a korelační koeficienty určující sílu vztahu mezi barvou získanou segmentací a barvou získanou predikcí pomocí PLSR modelu.

5.4. Porovnání populací

5.4.1. Porovnání populací na základě HSV

Pomocí modelu ASReml byly spočteny rozdíly mezi populacemi na základě parametrů HSV systému. Parametry barvy byly použity jako fixní efekt, heritabilita v užším smyslu byla odhadnuta jako náhodný efekt. Výsledky jsou rozepsány v tabulce 6. Jako testová statistika pro testování rozdílů mezi populacemi byl použit Waldův test, signifikance rozdílů je určena p-hodnotou. Likelihood-ratio test a jeho p-hodnota byly použity pro testování signifikance h^2 . U h^2 je taktéž uvedena střední chyba průměru.

Statisticky významnou rozdílnost vykazují populace v parametru odstínu a sytosti v září a říjnu. V lednu se populace statisticky neliší. Ačkoliv je heritabilita poměrně nízká, je signifikantní vždy alespoň v jednom parametru HSV v každém období. V říjnu je heritabilita signifikantní ve všech parametrech. Nejvyšší heritability dosahuje parametr H v září, a to přibližně 10,2 % se střední chybou průměru 0,03.

HSV v obdobích	Waldův test	p-hodnota (WT)	LR test	p-hodnota (LRT)	h^2	SE
H – září	57,764	$2,86 \times 10^{-13}$	8,935	0,001	0,102	0,034
S – září	33,590	$5,08 \times 10^{-8}$	$2,23 \times 10^{-6}$	0,499	$5,04 \times 10^{-8}$	0,000
V – září	2,856	0,240	17,704	$1,29 \times 10^{-5}$	0,100	0,025
H – říjen	12,199	0,002	3,186	0,037	0,055	0,032
S – říjen	123,357	$2,22 \times 10^{-25}$	1,613	0,102	0,044	0,034
V – říjen	5,671	0,0587	3,852	0,025	0,062	0,031
H – leden	4,737	0,094	$-7,71 \times 10^{-6}$	0,500	$1,01 \times 10^{-7}$	0,000
S – leden	1,384	0,501	0,386	0,267	0,020	0,031
V – leden	1,859	0,395	10,660	$5,5 \times 10^{-4}$	0,052	0,019

Tabulka 6: Hodnoty Waldova testu s jeho p-hodnotou a LR testu s jeho p-hodnotou a heritabilitou pro parametry HSV v různých obdobích.

Waldův test udává pouze informaci, zda jsou populace statisticky významně rozdílné, ale již neudává, které populace se případně liší. K tomuto účelu slouží mnohonásobné porovnávání. Signifikance byla ověřena pomocí plovoucí hodnoty LSD. Výsledky tohoto porovnání jsou uvedeny v tabulce 7. Vzhledem k tomu, že je hodnota LSD plovoucí, je uveden pouze její průměr.

HSV v období	Děčín–Plasy		Děčín–Třeboň		Plasy–Třeboň		LSD
	rozdíl	p-hodnota	rozdíl	p-hodnota	rozdíl	p-hodnota	
H – září	0,040	$2,95 \times 10^{-13}$	0,032	$2,88 \times 10^{-9}$	-0,040	$2,95 \times 10^{-13}$	0,0101
S – září	-0,073	$1,44 \times 10^{-6}$	-0,080	$6,76 \times 10^{-8}$	0,073	$1,44 \times 10^{-6}$	0,0283
V – září	0,002	0,886	0,020	0,1475	-0,002	0,886	0,0272
H – říjen	0,015	$4,99 \times 10^{-4}$	0,009	0,0202	-0,015	$4,99 \times 10^{-4}$	0,0077
S – říjen	-0,098	$1,02 \times 10^{-27}$	-0,062	$1,01 \times 10^{-12}$	0,098	$1,02 \times 10^{-27}$	0,0165
V – říjen	-0,012	0,531	-0,043	0,026	0,012	0,531	0,037
H – leden	0,008	0,125	0,011	0,030	-0,008	0,125	0,009
S – leden	0,001	0,947	0,010	0,329	-0,001	0,947	0,019
V – leden	-0,014	0,211	-0,004	0,747	0,014	0,211	0,022

Tabulka 7: Výsledky mnohonásobného porovnávání pro HSV a hodnota LSD použitá jako testová statistika.

Děčínská a plaská populace se liší vždy alespoň v jednom parametru HSV. V říjnu se liší ve všech třech parametrech. Zbylé dvě dvojice (Děčín–Plasy a Plasy–Třeboň) se liší v parametru H a S v září a říjnu. V lednu nejsou tyto dvojice statisticky rozdílné. Největší signifikanci rozdílů v září vykazuje parametr H, v říjnu je to parametr S.

5.4.2. Porovnání populací na základě RGB

Stejným způsobem jako u systému HSV byly i u systému RGB spočteny rozdíly mezi populacemi a heritabilita. Opět byly parametry barvy použity jako fixní efekt a heritabilita jako náhodný efekt. Výsledky jsou rozepsány v tabulce 8.

Statisticky významnou rozdílnost vykazují populace v září v parametru B a v říjnu parametru G a B. Ostatní parametry jsou v září a říjnu na pokraji signifikance. V lednu se populace dle RGB statisticky neliší. Heritabilita je opět poměrně slabá, střední chyba je také nízká. Nejvyšší heritabilitu vykazuje červený a zelený kanál RGB v září, přibližně 12,8 % a 10,6 %. Na rozdíl od HSV systému jsou heritability všech parametrů v lednu signifikantní, přestože je heritabilita slabá.

RGB v obdobích	Waldův test	p-hodnota (WT)	LR test	p-hodnota (LRT)	h^2	SE
R – září	5,602	0,061	19,049	6,37×10⁻⁶	0,1279	0,0302
G – září	5,530	0,063	22,535	1,03×10⁻⁶	0,1055	0,0241
B – září	19,043	7,33×10⁻⁵	0,218	0,320	0,0114	0,0240
R – říjen	5,769	0,056	4,047	0,022	0,0638	0,0311
G – říjen	8,832	0,012	0,019	0,445	0,0039	0,0260
B – říjen	24,184	5,60×10⁻⁶	-4,44×10 ⁻⁶	0,500	1,01×10 ⁻⁷	0,0000
R – leden	1,862	0,394	10,860	4,91×10⁻⁴	0,0527	0,0192
G – leden	4,211	0,122	13,517	1,18×10⁻⁴	0,0636	0,0197
B – leden	1,791	0,408	13,376	1,27×10⁻⁴	0,0642	0,0188

Tabulka 8: Hodnoty Waldova testu s jeho p-hodnotou a LR testu s jeho p-hodnotou a heritabilitou pro parametry RGB v různých obdobích.

V tabulce 9 jsou uvedeny výsledky mnohonásobného porovnávání mezi jednotlivými populacemi v různých obdobích. Přestože p-hodnoty byly u Waldova testu často na hranici signifikance, u některých porovnávaných dvojic výsledky mnohonásobného porovnávání ukazují signifikantní rozdíl. V září a říjnu byly všechny dvojice populací rozlišeny vždy alespoň v jednom parametru RGB. V lednu byly rozlišeny pouze dvojice Děčín – Plasy a Plasy – Třeboň, a to pouze na hranici významnosti. To odpovídá výsledkům předešlého Waldova testu.

RGB v obdobích	Děčín – Plasy		Děčín - Třeboň		Plasy - Třeboň		LSD
	rozdíl	p-hodnota	rozdíl	p-hodnota	rozdíl	p-hodnota	
R – září	-8,784	0,024	-2,914	0,442	8,784	0,024	7,295
G – září	5,935	0,108	8,386	0,020	-5,935	0,108	6,944
B – září	10,387	0,002	13,776	1,93×10⁻⁵	-10,387	0,002	6,228
R – říjen	-3,307	0,512	-11,120	0,024	3,307	0,512	9,505
G – říjen	6,964	0,063	-2,897	0,428	-6,964	0,063	7,046
B – říjen	10,335	6,04×10⁻⁶	2,411	0,277	-10,335	6,04×10⁻⁶	4,290
R – leden	-3,699	0,210	-0,932	0,745	3,699	0,210	5,503
G – leden	-4,564	0,045	-2,047	0,351	4,564	0,045	4,196
B – leden	-2,664	0,197	-2,141	0,283	2,664	0,197	3,829

Tabulka 9: Výsledky mnohonásobného porovnávání pro RGB a hodnota LSD použitá jako testová statistika.

6. Diskuze

6.1. Segmentace semenáčků borovic

V zemědělství je obrazová segmentace RGB nebo HSV snímků listů již poměrně běžnou technikou využívanou například k odhadu jejich stáří (Bai et al. 2023) nebo pro následnou segmentaci nekrotických a lézí v rámci listu (Hu et al. 2017). Segmentace listů krytosemenných rostlin je v již pokročilé fázi, a může být využita i u dřevin, například pro odhad chlorofylu a dalších rostlinných barviv nebo k odlišení jednotlivých druhů stromů (Mielke et al. 2021). Využití segmentačních algoritmů pro segmentaci jehlic u nahosemenných stromů se však v praxi nepoužívá a studie, které by řešily problematiku obrazové segmentace jehlic neexistují.

Tvar jehlic a jejich překrývání jsou faktory, které brání efektivní „*unsupervised*“ segmentaci. Proto se algoritmus YOLOv7 jeví jako velmi vhodná alternativa s úspěšností segmentace více než 99 %. Na rozdíl od nesupervizovaných metod je však tato metoda časově náročná vzhledem k nutné anotaci.

V tomto segmentačním modelu byly využity pro anotaci pouze semenáčky borovice lesní. Pokud by byly použity i semenáčky jiných druhů dřevin, mohla by vzrůst robustnost segmentačního modelu a zároveň by mohl být model použit pro segmentaci více druhů stromů, při použití jednoho modelu. Současný model byl trénován na velkém množství semenáčků, které se tvarově poměrně lišily a je tedy robustní sám o sobě. Zároveň podobnost semenáčků ostatních důležitých jehličnanů (smrk a jedle), které u nás rostou, je z pohledu segmentačního modelu poměrně vysoká a je tedy pravděpodobné, že současný model je využitelný i pro segmentaci semenáčků jiných druhů jehličnanů.

Jako problematický krok se může zdát standardizace dat pomocí bílé reference. Sonnentag et al. (2012) uvádějí, že pro porovnatelnost by měl být použit referenční panel. V této práci byl použit jako reference bílý papír, jelikož původní účel fotografií nebyl určen pro segmentaci a následné srovnávání. V ideálním případě by však měl být pro standardizaci použit referenční panel s více odstíny šedé a také s barevnými terčí (Sonnentag et al. 2012). Fotografie však byly pořizovány vždy v co nejkratší době, aby se zamezilo např. změně osvětlení. Ideálním formátem pořizované fotografie je RAW, nicméně bylo prokázáno, že vliv komprese na jiné formáty (JPEG, PNG) je u fenologických měření zanedbatelný. Zanedbatelný je i vliv použitého fotoaparátu (Sonnentag et al. 2012).

6.2. Fenologie – změna barvy v různých obdobích

6.2.1. Fenologie – změna parametrů barevného systému HSV v různých obdobích

Vzhledem ke složité segmentaci jehlic neexistuje mnoho studií, které by se zabývaly fenologií a změnou barvy na úrovni jehlice, a pokud již existují, využívají systém RGB a nikoliv HSV. Rozdíly v jednotlivých obdobích jsou však z obrázku 23 zjevné. Bylo prokázáno, že s rostoucím obsahem chlorofylu listy užitkových plodin tmavnou v důsledku vyšší optické tloušťky chlorofylu (Kawashima, Nakatani 1998). Tomu odpovídá i významný rozdíl v jas u lednových semenáčků. S přicházejícím podzimem obsah chlorofylu klesá a jas by se tedy měl zvyšovat. Poměrně obdobná míra jas u zářijových a říjnových semenáčků může být vysvětlena projevem doposud potlačených karotenoidů a tvorbou antokyanů. Ty do jisté míry kompenzují ubývající tmavost chlorofylu. Od určitého stádia však projevující se pigmenty nedokáží kompenzovat ztrátu jas způsobenou rozpadem chlorofylu a jehlice světlají.

Rozdíl mezi barvami v září a říjnu je způsoben zejména jiným odstínem a částečně i sytostí. Zelená barva jehličí v září je způsobena absorpčními maximy chlorofylu. Na podzim se obsah chlorofylu snižuje a projevují se karotenoidy. Dokud se neprojeví vliv antokyanů, přechází barva do žluté nebo oranžové. (Archetti 2009). Je obvyklé, že na rozdíl od dospělých stromů, semenáčky jehličnanů vytvářejí se snižujícími se teplotami větší množství antokyanů, což způsobuje změnu jejich barvy směrem k červené (Chalker-Scott, 1999). Kombinace těchto faktorů způsobuje změnu odstínu a saturace mezi zářím a říjnem.

Obrázek 24 taktéž vyobrazuje popsanou změnu odstínu a saturace. S ubývajícím chlorofylem se barva postupně mění ze zelené na oranžovou a z té na červenou. Saturace je v barvách září a října obdobná, avšak u lednových barev klesá. Podobný průběh je vidět i na obrázku 23. Přestože by se dalo předpokládat, že odstín reprezentuje reálnou barvu listu nejlépe a bude tedy úzce souviset s obsahem chlorofylu, studie prováděná na listech čiroku ukázala, že ještě lepší korelaci s obsahem chlorofylu poskytuje sytost (Zhang et al. 2022). Z toho lze uvažovat, že změna sytosti mezi říjnem a lednem je způsobená, právě snížením obsahu chlorofylu.

Obrázek 24 také ukazuje rozdíly v barvě mezi jednotlivými populacemi. V září a říjnu je vždy odskočena průměrná barva děčínské populace. To odpovídá původu těchto populací. Děčínská populace jako jediná patří k náhornímu ekotypu, zatímco plaská a třeboňská

populace patří k ekotypu chlumnímu. Lednové průměry se však na barevném kole téměř zcela překrývají. To může být způsobeno právě postupnou fenologií, kdy odlišné populace postupně spějí až k finálnímu stavu, který je pro všechny populace shodný a liší se pouze termíny, kdy k němu dospějí.

6.2.2. Fenologie – změna parametrů barevného systému RGB v různých obdobích

Na rozdíl od systému HSV lze hodnoty RGB lépe vztáhnout k viditelnému spektru. Červený, zelený a modrý kanál systému RGB reprezentují červené, zelené a modré pásmo spektra a změna jejich poměrů je tedy snáze interpretovatelná.

Chlorofyly, jako nejhojnější pigmenty v listech, ovlivňují barvu listu nejvíce, avšak obsah a poměr těchto pigmentů se u různých druhů značně liší (Sims, Gamon 2002). Obsah chlorofylu a dalších pigmentů, jako jsou antokyany nebo karotenoidy ovlivňuje odrazivost v různých pásmech vlnových délek, což způsobuje změnu barvy listu, a tedy i změnu hodnot R, G a B (Gamon, Surfus 1999).

Interpretace obrázku 25 je poměrně jasná. Rozdíl mezi barvami v září a říjnu je největší podél komponenty tvořené zelenou barvou. Změna hodnoty zeleného kanálu RGB je pravděpodobně způsobena poklesem obsahu zeleného chlorofylu. Říjen a leden se pak příliš v zeleném kanálu neliší, důležitější jsou spíše komponenty R a B. Kombinací těchto dvou složek vzniká fialová barva. Tu lze vysvětlit vznikem antokyanů. Dle obrázku 25 lze tedy usuzovat, že rozdíl mezi zářím a říjnem je zejména v obsahu chlorofylu, zatímco rozdíl v říjnu a lednu je způsoben větším obsahem antokyanů.

Na druhou stranu studie prováděná na semenáčcích tropických dřevin ukázala, že obsah chlorofylu je z parametrů RGB nejlépe vysvětlen složkou R (do Amaral et al. 2019). To potvrzuje i fakt, že absorpční maximum chlorofylu se nachází v červeném kanálu (Taiz, Zeiger 2002). Nicméně tato interpretace nemusí být v rozporu s výsledky této práce. Změna červené složky na obrázku 25 nemusí nutně indikovat pouze tvorbu antokyanů, ale i úbytek chlorofylů.

6.3. Korelace barev získaných segmentací a barev získaných z hyperspektrálních dat

6.3.1. Korelace barev ze segmentace a barev vypočtených z hyperspektrálních dat pomocí kolorimetrických funkcí

Vztahy mezi parametry barvy získanými ze zářijových fotografií a stejnými parametry vypočtenými pomocí kolorimetrických funkcí z hyperspektrálních dat jsou uvedeny v tabulce 4. Korelace nedosahují příliš vysokých hodnot. To může být způsobeno několika faktory. Jedním z nejdůležitějších faktorů je rozdílná doba měření, případně focení semenáčků. Přestože fotografie byly pořízeny v krátkém časovém úseku, fotografování proběhlo v jinou dobu než měření hyperspektrálních dat optickým kabelem. Zároveň měření hyperspektrálních dat probíhalo delší dobu a ve dvou dnech. Přestože byla hyperspektrální data normalizována pomocí bílé reference, rozdílné časy mohly způsobit i větší rozdíly mezi výslednými parametry barevných systémů. Dalším faktorem může být fakt, že barva u segmentovaných semenáčků byla získána pouze z pixelů s barvou jehlice. Naproti tomu, při měření hyperspektrálních dat byla snímána i odrazivost podkladu. Tento podklad je pak vzhledem k různé hustotě jehlic zastoupen různým poměrem, který se poté promítá do výpočtu barvy pomocí kolorimetrických funkcí. Zároveň bylo pro výpočet použito typické denní osvětlení D65 dle CIE. Jedná se o uměle spočítané osvětlení, které by mělo odpovídat klasickému dennímu světlu (Kasajima 2019). Nicméně reálné denní světlo, ve kterém byla hyperspektrální data měřena, se pravděpodobně od D65 lišilo, a tedy i výsledné barvy mohou být mírně odlišné. Posledním důležitým faktorem může být standardizace fotografií pomocí bílého papíru jako reference. Přestože jsou barvy v rámci jednoho focení porovnatelné, tato standardizace není provedena optimálním způsobem. Jelikož je použit pouze jeden odstín jako reference, není dosaženo shodné změny barvy pro všechny kanály (Sonnentag et al. 2012). To může být důvodem pro to, že korelace jednotlivých RGB kanálů je slabá.

Nejsilnější korelaci (cca 52 %) vykazuje odstín. Na rozdíl od RGB kanálů, odstín do jisté míry popisuje barvu jehlic sám o sobě. Nasycení tohoto odstínu a jeho jas lze chápat pouze jako úpravu v rámci odstínu (Berns 2019). To pravděpodobně způsobuje nejsilnější korelaci oproti ostatním parametrům.

6.3.2. Korelace barev ze segmentace a barev predikovaných z hyperspektrálních dat pomocí modelů PLSR

Korelace predikovaných parametrů a parametrů získaných ze segmentace vychází významně vyšší (tabulka 5). Jedním z důvodů, proč PLSR předpovídá barvu lépe, než je získána pomocí kolorimetrických funkcí, může být i fakt, že do modelu byly zahrnuty vlnové délky v rozmezí 350–750 nm. Jsou tedy zahrnuty i vlnové délky na pokraji viditelnosti, ale právě tyto délky se v modelu významně podílejí se na tvorbě barvy.

Nejlépe vychází korelace mezi parametry vytvořenými modelem a segmentovanými parametry u odstínu. V příloze 6 je vidět, že nejdůležitější jsou pro tvorbu modelu vlnové délky v oblasti červeného pásma a red-edge. Zelená barva jehlic je v září tvořena zejména chlorofyly (Sims, Gamon 2002), ty vzhledem ke svému absorpčnímu maximu souvisí s reflektancí v červeném pásmu VIS a s red-edge (Carter, Knapp 2001). Jelikož je odstín jehlic zelený, je logické, že největší importance budou právě v těchto oblastech. Zároveň sytost a jas vyjadřují i obsah ostatních barviv, tomu odpovídají importance vlnových délek uvedené v příloze 6, které zasahují i do modrého pásma VIS.

U barvy z modelu PLSR a RGB barvy ze segmentace koreluje nejlépe červený kanál. Důvod bude podobný jako u odstínu, kanál R se nejvíce podílí na barvě listu, jelikož zde leží absorpční maximum chlorofylu. Opět je důležitá i oblast red-edge. U zbylých parametrů RGB se korelace snižuje. To může být způsobeno opět tím, že tyto parametry odpovídají absorpčním maximům antokyanů nebo karotenoidů, které se na barvě v září zatím příliš neprojevují.

6.4. Porovnání populací

6.4.1. Porovnání populací na základě HSV

Jak již bylo zmíněno, semenáčky jehličnanů mají na rozdíl od dospělců tendenci na konci vegetačního období zčervenat, jako reakci na chlad (Chalker-Scott 1999). Tento projev ale může být závislý na populaci nebo ekotypu. Studie prováděná na semenáčcích borovice lesní ukázala, že populace rostoucí ve vyšších zeměpisných šířkách jsou mrazuvzdornější (Taulavuori et al. 2010). Populace z chladnějších oblastí jsou obecně odolnější vůči chladu (White et al. 2007). To lze z části připsat právě rostlinným barvivům (Chalker-Scott 1999). Z výsledků v tabulce 6 vychází, že se populace na základě HSV liší v parametrech odstínu a sytosti v září a říjnu. Nejvýznamnější rozdíly

se nachází v parametru sytosti v říjnu. Tyto největší rozdíly se nacházejí v říjnu pravděpodobně právě proto, že dochází k přebarvování jehličí v závislosti na ekotypové nebo populační příslušnosti. V září, na konci vegetační sezóny se již začínají projevovat rozdíly, ale nejsou tak vysoké. Maximální rozdíly nastávají na podzim, a v lednu jsou již všechny ekotypy přebarveny, a proto zde významné rozdíly mezi populacemi chybí.

Přestože patří děčínská populace k náhornímu ekotypu a měla by se lišit nejvíce mnohonásobné porovnávání ukazuje odlišné výsledky. Přestože jsou rozdíly mezi dvojicemi populací v září a říjnu signifikantní, dvojice Děčín–Třeboň vykazuje nejmenší rozdíly (tabulka 7). Na druhou stranu podobné výsledky ukazovalo i porovnání stejných populací pomocí hyperspektrálních dat měřených optickým kabelem (Chuchlík 2022).

Heritabilita nedosahuje vysokých hodnot (0,05–0,10). U parametrů odstínu a jasu v září a říjnu a u parametru jasu v říjnu je však signifikantní (tabulka 6). Nízké hodnoty h^2 u rostlinných pigmentů uvádí také studie prováděná na 2 populacích borovice lesní. Jako důvod pro nízké hodnoty je uváděn fenotypový předvýběr pro semenné sady (Čepl et al. 2018). Lze tedy předpokládat, že nízkých hodnot je dosaženo ze stejného důvodu, jelikož semenný materiál pochází také ze semenných sadů.

6.4.2. Porovnání populací na základě RGB

Rozdílnost populací zjišťovaná pomocí parametrů RGB nedosahuje takové signifikance jako parametry HSV. Statisticky významný je pouze modrý kanál v září a zelený a modrý kanál v říjnu (tabulka 8). To může být způsobeno tím, že jednotlivé kanály samy o sobě nepopisují odstín nebo barvu, ale k vytvoření výsledné barvy je potřeba všech 3 parametrů RGB. Avšak intenzitu jednotlivých barevných kanálů lze také chápat jako souhrnnou hodnotu pro jednotlivá pásma VIS a lze ji považovat za charakteristiku obsahu pigmentů v daném rozsahu vlnových délek. Jednotlivé pigmenty však nestačí k odlišení populací, je potřeba zahrnout více informací, jako u HSV.

Při mnohonásobném porovnávání se ukázaly signifikantní rozdíly i u dvojic, které neprošly testovou statistikou, nicméně u všech signifikantně odlišných dvojic byl Waldův test alespoň na pokraji signifikance. V září a říjnu byly dvojice populací rozlišeny vždy alespoň pomocí jednoho parametru. To lze interpretovat podobně jako rozdíly u HSV. V září a říjnu probíhají fenologické změny v barvě jehličí a různé ekotypy reagují na změnu počasí odlišnou rychlostí. Proto i zde nacházíme více rozdílů. V lednu je již obsah pigmentů ustálený a jednotlivé populace se více podobají, zde nacházíme rozdíly

pouze v zeleném kanálu u dvojic Plasy–Děčín a Plasy–Třeboň. Přestože by se měl vzhledem k ekotypové příslušnosti nejvíce odlišovat Děčín, dvojice Děčín–Třeboň jako jediný v lednu nevykazuje signifikantní rozdíly, dokonce ani rozdíly na hranici významnosti. To odpovídá dosavadním výsledkům získaným z parametrů HSV i z hyperspektrálních dat (Chuchlík 2022).

Heritabilita kanálů RGB opět nedosahuje vysokých hodnot (0,05–0,12), nicméně opět jsou tyto nízké hodnoty signifikantní. Pouze červený kanál je signifikantní ve všech 3 měřených obdobích. To lze vysvětlit h^2 spojenou s obsahem chlorofylu, vzhledem k jeho absorpčnímu maximu. Naproti tomu, Čepl et al. (2018) uvádí, že h^2 populací zjišťovaná po 1 nm z hyperspektrálních dat, nebyla v oblasti červeného kanálu signifikantní. Jedná se však odlišný typ dat. Červený kanál, na rozdíl od hyperspektrálních dat, je výstup z celého červeného pásma, a to může ovlivnit finální výsledek.

Limitací porovnání populací jak na základě parametrů RGB, tak i HSV je absence znáhodnění replikací v rámci experimentu. Z přílohy 1 je patrné, že jednotlivé sadbovače se stejnými populacemi a rodinami nebyly randomizovány a byly pěstovány pouze v jednom bloku.

7. Závěr

Aplikace algoritmu YOLOv7 na semenáčky borovice lesní je velmi účinná metoda pro segmentaci obrazových dat. Z takto segmentovaných fotografií lze automatizovaně získat mnoho důležitých informací o stavu segmentovaných objektů. Vzhledem k obtížné segmentaci semenáčků jehličnanů se tento postup jeví jako ideální metoda použitelná pro mnoho účelů a robustnost vytvořených modelů dává předpoklad pro segmentaci i dalších druhů jehličnatých semenáčků.

Výsledky fenologického pozorování jasně ukazují odlišnosti v rámci měřených období. Tyto odlišnosti vycházejí z různého obsahu rostlinných pigmentů. Pro popis fenologie pomocí obrazových dat je vhodnější použití RGB systému, vzhledem k tomu, že lépe odpovídá barevným projevům jednotlivých pigmentů. Na druhou stranu, zobrazení na barevném kole (odstín a sytost) lépe zobrazuje barevný posun a fenologické rozdíly mezi populacemi.

Korelace mezi segmentovanými barvami a barvami spočtenými z hyperspektrálních dat nevycházejí příliš dobře, vzhledem k faktorům, které vstupovaly do výpočtů. Na druhou stranu lze z této práce vyvodit potřebu použití vhodné referenční tabulky pro porovnatelnost fotografií pro další studie. Z modelů PLSR lze zároveň vyvodit vysokou významnost vlnových délek mimo viditelné spektrum.

Pomocí parametrů barevných systémů HSV a RGB lze odlišit jednotlivé populace. Výsledky ukazují statisticky významné rozdíly mezi populacemi, zejména v září a říjnu. V těchto měsících se liší reakce semenáčků na změny počasí v závislosti na populaci. Rozdíly mezi populacemi se smývají v lednu, kdy již nejsou signifikantní. Pro rozlišení populací je vhodnější použití systému HSV, jelikož lépe popisuje barevné rozdíly mezi populacemi než jednotlivé kanály RGB. Heritabilita jednotlivých parametrů není vysoká, nicméně v mnoha případech je statisticky významná.

Segmentační algoritmus určený pro semenáčky jehličnanů může být využit ve vědecké sféře pro získávání informací z obrazu, ale stejně tak i ve šlechtitelských programech nebo lesních školkách pro následné zjišťování zdravotního stavu nebo obsahu pigmentů. Informace o barevné odlišnosti mezi populacemi mohou být využity ve šlechtitelských programech. Zároveň mohou sloužit k nenáročnému a nedestruktivnímu genetickému hodnocení na úrovni jednotlivých populací. Výsledky této práce vedly k rozhodnutí o pořizování fotografií v rámci projektu Horizon OptFORESTS .

8. Seznam použité literatury

ABDI, H. Partial least squares regression and projection on latent structure regression (PLS Regression). *WIREs Computational Statistics* [online]. 2010, vol. 2, no. 1, p. 97-106. [cit. 2024-02-28]. ISSN 1939-5108. Dostupné z: <https://doi.org/10.1002/wics.51>.

AHLIHA, A., H.; NUROSYID, F.; SUPRIYANTO, A.; KUSUMANINGSIH, T. Optical properties of anthocyanin dyes on TiO₂ as photosensitizers for application of dye-sensitized solar cell (DSSC). *IOP Conference Series: Materials Science and Engineering* [online]. 2018, vol. 333, no. 1. [cit. 2024-02-25]. Dostupné z: <https://doi.org/10.1088/1757-899X/333/1/012018>.

ALBRECHTOVÁ, J.; KUPKOVÁ, L.; CAMPBELL, P. K. E. (eds.). *Hodnocení stavu smrkových porostů. - Případové studie sledování vývoje fyziologického stavu smrkových porostů v Krušných horách v letech 1998–2013*. Praha: Geographica - Česká geografická společnost, 2017. ISBN 978-80-905642-9-9

ARCHETTI, M.; DÖRING, T.; HAGEN, S., B.; HUGHES, N., M.; LEATHER, S., R. et al. Unravelling the evolution of autumn colours: an interdisciplinary approach. *Trends in Ecology & Evolution* [online]. 2009, vol. 24, no. 3, p. 166-173. [cit. 2024-03-28]. ISSN 01695347. Dostupné z: <https://doi.org/10.1016/j.tree.2008.10.006>.

ASD Inc. *FieldSpec® 3 User Manual*. ASD Document 600540 Rev. J, 2010.

BAI, Y.; SHI, L.; ZHA, Y.; LIU, S.; NIE, C. et al. Estimating leaf age of maize seedlings using UAV-based RGB and multispectral images. *Computers and Electronics in Agriculture* [online]. 2023, vol. 215. [cit. 2024-03-14]. ISSN 01681699. Dostupné z: <https://doi.org/10.1016/j.compag.2023.108349>.

BENTHAM INSTRUMENTS LTD. *A guide to spectroradiometry: Instruments & Applications for the Ultraviolet* [online]. Reading, 1997. [cit. 2024-02-26]. Dostupné z: <https://www.wonwoosystem.co.kr/pic/catalog/UVGuide.pdf>.

BERNS, R., S. *Billmeyer and Saltzman's principles of color technology*. [online]. 4th ed. Hoboken: Wiley, 2019. [cit. 2024-02-26]. ISBN 9781119367314. Dostupné z: <https://doi.org/10.1002/9781119367314>.

BUTLER, D., G.; CULLIS, B., R.; GILMOUR, A., R.; GOGEL, B., J. a TOMPSON, R. *ASReml-R Reference Manual Version 4*. Hemel Hempstead: VSN International Ltd., 2017.

CARTER, G., A. a KNAPP, A., K. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. *American Journal of Botany* [online]. 2001, vol. 88, no. 4, p. 677-684. [cit. 2024-03-14]. ISSN 0002-9122. Dostupné z: <https://doi.org/10.2307/2657068>.

CAVENDER-BARES, J.; MEIRELES, J.; COUTURE, J.; KAPROTH, M.; KINGDON, C. a kol. Associations of Leaf Spectra with Genetic and Phylogenetic Variation in Oaks: Prospects for Remote Detection of Biodiversity. *Remote Sensing* [online]. 2016, vol. 8, no. 3 [cit. 2024-02-28]. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs8030221>.

ČEPL, J.; STEJSKAL, J.; LHOTÁKOVÁ, Z.; HOLÁ D.; KORECKÝ J. a kol. Heritable variation in needle spectral reflectance of Scots pine (*Pinus sylvestris* L.) peaks in red edge. *Remote Sensing of Environment* [online]. 2018, vol. 219 [cit. 2024-02-28]. ISSN 00344257. Dostupné z: <https://doi.org/10.1016/j.rse.2018.10.001>.

Český hydrometeorologický ústav. *Historická data – meteorologie a klimatologie* [online]. [2022] [cit. 2022-03-22]. Dostupné z : <https://www.chmi.cz/historicka-data/pocasi/>.

DO AMARAL, E., S.; VIEIRA SILVA, D.; DOS ANJOS, L.; SCHILLING, A., C.; DALMOLIN, Â., C. et al. Relationships between reflectance and absorbance chlorophyll indices with RGB (Red, Green, Blue) image components in seedlings of tropical tree species at nursery stage. *New Forests* [online]. 2019, vol. 50, no. 3, p. 377-388. [cit. 2024-03-14]. ISSN 0169-4286. Dostupné z: <https://doi.org/10.1007/s11056-018-9662-4>.

DODGE, Y. *The Concise Encyclopedia of Statistics* [online]. New York: Springer, NY, 2008. [cit. 2024-02-28]. ISBN 978-0-387-31742-7. Dostupné z: <https://doi.org/10.1007/978-0-387-32833-1>.

DURAZZO, B., D. *Contemporary applications of light-emitting diodes in horticulture: A review on LED lighting technology and the use of wavelength band and irradiance modulation to study plant photobiology* [online]. 2021 [cit. 2024-02-26]. Dostupné z: <https://doi.org/10.13140/RG.2.2.17101.77282>.

EL-KASSABY, Y. A.; LSTIBŮREK, M. Breeding without breeding. *Genetics Research* [online]. 2009, vol. 91, no. 2 [cit. 2024-02-28]. ISSN 0016-6723. Dostupné z: <https://doi.org/10.1017/S001667230900007X>.

EL-KASSABY, Y., A.; KLÁPŠTĚ, J. *Tree Breeding - Challenges and Opportunities*. [online]. 2016 [cit. 2024-02-28].

Dostupné z: <https://www.researchgate.net/publication/311452542>

ERIKSSON, G.; EKBERG, I.; CLAPHAM, D. *An introduction to forest genetics*. 2nd ed. Uppsala: Genetic Center, Department of Plant Biology and Forest Genetics, SLU, 2006. 186 p. ISBN 91-576-7190-7.

FOX, C. W.; REED, D. H. Inbreeding depression increases with environmental stress: an experimental study and meta-analysis. *Evolution* [online]. 2011, vol. 65, no. 1 [cit. 2024-02-28]. ISSN 00143820. Dostupné z: <https://doi.org/10.1111/j.1558-5646.2010.01108.x>.

FUNDA, T.; EL-KASSABY, Y. A. Seed orchard genetics. *CAB Reviews: Perspectives in Agriculture, Veterinary Science, Nutrition and Natural Resources* [online]. 2012, vol. 7, no. 13 [cit. 2024-02-28]. ISSN 17498848. Dostupné z: <http://dx.doi.org/10.1079/PAVSNNR20127013>.

GAMON, J. A.; SURFUS, J. S. Assessing leaf pigment content and activity with a reflectometer. *New Phytologist* [online]. 1999, vol. 143, no. 1, p. 105-117. [cit. 2024-03-14]. ISSN 0028-646X. Dostupné z: <https://doi.org/10.1046/j.1469-8137.1999.00424.x>.

GILMOUR, A. R.; GOGEL, B. J.; CULLIS, B. R.; THOMPSON, R. *ASReml User Guide*. Hemel Hempstead: VSN International Ltd., 2009. 372 p.

GOOGLE, LCC. *Google Colab* [online]. [cit. 2024-03-28]. Dostupné z: <https://colab.research.google.com/>.

HANBURY, A. Circular Statistics Applied to Colour Images. Online. In: DRBOHLAV, O. (ed.). *Proceedings of the Computer Vision Winter Workshop 2003*. Praha: Czech pattern recognition society, 2003, p. 55-60. [cit. 2024-02-28]. ISBN 80-238-9967-8. Dostupné z: <https://www.researchgate.net/publication/2905149>.

HÁJKOVÁ, L. *Atlas fenologických poměrů Česka: Atlas of the phenological conditions in Czechia*. Praha: Český hydrometeorologický ústav, 2012. ISBN 978-80-86690-98-8.

HEJNÝ, S.; SLAVÍK, B. (ed.). *Květena České socialistické republiky: 1*. Praha: Academia, 1988.

HOLLAND, S. M. *Principal components analysis (PCA)*. Athens: University of Georgia, Department of Geology, [online] 2019. 12 p. [cit. 2024-02-28]. Dostupné z: <http://stratigrafia.org/8370/handouts/pcaTutorial.pdf>.

HOSSAIN, M., D.; CHEN, D. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing* [online]. 2019, vol. 150, p. 115-134. [cit. 2024-02-28]. ISSN 09242716. Dostupné z: <https://doi.org/10.1016/j.isprsjprs.2019.02.009>.

HU, Q.; TIAN, J. a HE, D. Wheat leaf lesion color image segmentation with improved multichannel selection based on the Chan–Vese model. *Computers and Electronics in Agriculture* [online]. 2017, vol. 135, p. 260-268. [cit. 2024-03-14]. ISSN 01681699. Dostupné z: <https://doi.org/10.1016/j.compag.2017.01.016>.

CHALKER-SCOTT, L. Environmental Significance of Anthocyanins in Plant Stress Responses. *Photochemistry and Photobiology* [online]. 1999, vol. 70, no. 1, p. 1-9. [cit. 2024-02-28]. ISSN 0031-8655. Dostupné z: <https://doi.org/10.1111/j.1751-1097.1999.tb01944.x>.

CHALOUPKOVÁ, K.; STEJSKAL, J.; EL-KASSABY, Y. A.; LSTIBŮREK, M. Optimum neighborhood seed orchard design. *Tree Genetics & Genomes* [online]. 2016, vol. 12, no. 105 [cit. 2024-02-25]. Dostupné z: <https://doi.org/10.1007/s11295-016-1067-y>.

CHEN, J.; CRANTON, W.; FIHN, M. *Handbook of visual display technology*. New York: Springer, 2012. ISBN 9783540795681.

CHUCHLÍK, J. *Hodnocení hyperspektrální reflektance a růstových parametrů v časném testu potomstev borovice lesní*. Praha, 2022. Bakalářská práce. Česká zemědělská univerzita, Fakulta lesnická a dřevařská, Katedra genetiky a fyziologie lesních dřevin. Vedoucí práce Ing. Jan Stejskal, PhD.

INTERNATIONAL COMMISSION ON ILLUMINATION. *CIE 15:2004, Technical Report: Colorimetry*. 3rd ed. 2004.

- IVANEK, O.; NOVOTNÝ P.; FRÝDL J. *Metodika zakládání semenných sadů 1,5. generace: certifikovaná metodika*. Strnady: Výzkumný ústav lesního hospodářství a myslivosti, 2010. 29 p. ISBN 978-80-7417-037-9.
- JAADI, Z. A step-by-Step Explanation of Principal Component Analysis (PCA). *builtin: data-science* [online]. 2021 [cit. 2024-02-28]. Dostupné z: <https://builtin.com/data-science/step-step-explanation-principal-component-analysis>.
- JACQUEMOUD, S.; USTIN, S., L. *Leaf optical properties*. New York: Cambridge University Press, 2019. ISBN 9781108481267.
- JENSEN, J. R. *Remote Sensing of the Environment: an Earth Resource Perspective*. 2nd ed. Upper Saddle River: Pearson Education, 2014. 614 p. ISBN 13:978-1-292-02170-6.
- KAŇÁK, J. *Metodika zakládání semenných sadů: recenzovaná metodika*. Jiloviště: Výzkumný ústav lesního hospodářství a myslivosti, 2008. 24 p. ISBN 978-80-7417-007-2.
- KAŇÁK, J. *Arboretum Sofronka: 1956-2016*. Plzeň: RAMAP, [2016]. ISBN 978-80-906648-0-7.
- KAŇÁK, J.; KLÁPŠTĚ, J.; LSTIBŮREK, M. Úvodní genetické hodnocení semenných sadů borovice lesní v západních Čechách. *Zprávy lesnického výzkumu*. 2009, vol. 53, no. 3, p. 189-204. ISSN 1805-9872.
- KANTOR, J. *Zakládání lesů a šlechtění lesních dřevin*. Praha: Státní zemědělské nakladatelství, 1975. 526 p.
- KASAJIMA, I. Measuring plant colors. *Plant Biotechnology* [online]. 2019, vol. 36, no 2, p. 63-75. [cit. 2024-02-26]. Dostupné z: <https://doi.org/10.5511/plantbiotechnology.19.0322a>.
- KAWASHIMA, S.; NAKATANI, M. An Algorithm for Estimating Chlorophyll Content in Leaves Using a Video Camera. *Annals of Botany* [online]. 1998, vol. 81, no. 1, p. 49-54. ISSN 03057364. [cit. 2024-03-14]. Dostupné z: <https://doi.org/10.1006/anbo.1997.0544>.
- KIM, P.,V. Chameleon-like weather presenter costume composite format based on color fuzzy model. *Soft Computing* [online]. 2018, vol. 22, p. 1491-1500. [cit. 2024-02-26]. Dostupné z: <https://doi.org/10.1007/s00500-017-2868-0>.

KNIPLING, E., B. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment* [online]. 1970, vol. 1, no. 3, p. 155-159. [cit. 2024-02-26]. ISSN 0034-4257. Dostupné z: [https://doi.org/10.1016/S0034-4257\(70\)80021-9](https://doi.org/10.1016/S0034-4257(70)80021-9).

KOBLÍŽEK, J. *Systematická botanika lesnická*. Dot. Brno: Mendelova zemědělská a lesnická univerzita, 1999. 168 p. ISBN 80-715-7188-1.

KONG, J., M.; CHIA, L., S.; GOH, N., K.; CHIA, T., F.; BROUILLARD, R. Analysis and biological activities of anthocyanins. *Phytochemistry* [online]. 2003, vol. 64, no. 5, p. 923-933. [cit. 2024-02-28]. ISSN 00319422. Dostupné z: [https://doi.org/10.1016/S0031-9422\(03\)00438-2](https://doi.org/10.1016/S0031-9422(03)00438-2).

KRŠKA, K. Fenologie jako nauka, metoda a prostředek. In: ROŽNOVSKÝ, J.; LITSCHMANN, T. a VYSKOT, I. (ed.). *Fenologická odezva proměnlivosti podnebí: sborník referátů*. Praha: Czech hydrometeorological Institute, 2006. ISBN 80-86690-35-0.

KWIECIEN, A. Pinus sylvestris range. *Wikimedia commons* [online]. 2017-12-10 [cit. 2024-02-28]. Dostupné z: https://commons.wikimedia.org/wiki/File:Pinus_sylvestris_range-01.png.

LARCHER, W. *Physiological plant ecology: ecophysiology and stress physiology of functional groups*. 4th ed. Berlin: Springer-Verlag, 2003. 513 p. ISBN 3-540-43516-6.

LEE, H., C. *Introduction to color imaging science*. New York: Cambridge University Press, 2005. ISBN 052184388X.

LIN, T. Y.; MAIRE, M.; BELONGIE, S.; HAYS, J.; PERONA, P. et al. Microsoft COCO: Common Objects in Context. Online. In: FLEET, D.; PAJDLA, T.; SCHIELE, B.; TUYTELAARS, T. (ed.). *Computer Vision – ECCV 2014. Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2014, p. 740-755. [cit. 2024-02-28]. ISBN 978-3-319-10601-4. Dostupné z: https://doi.org/10.1007/978-3-319-10602-1_48.

LIN, Y., T.; FINLAYSON, G., D. Per-Channel Regularization for Regression-Based Spectral Reconstruction. In: *Colour and Visual Computing Symposium (CEUR workshop proceeding)* [online]. Gjøvik: Norwegian University of Science and Technology, 2020. [cit. 2024-02-26]. Dostupné z: <https://ceur-ws.org/Vol-2688/paper8.pdf>.

- LUCCHESI, L. a MITRA, S., K. Color Image Segmentation: A State-of-the-Art Survey. *Proceedings of Indian National Science Academy*. 2001, vol. 2. ISSN 0370-0046.
- MADĚRA, P.; ÚRADNÍČEK, L. *Dřeviny České republiky*. Písek: Matice lesnická, 2001. 333 p. ISBN 80-862-7109-9.
- MÁCHOVÁ, P.; CVRČKOVÁ, H.; POLÁKOVÁ, L.; TRČKOVÁ, O. Genetická variabilita vybraných populací borovice lesní v České republice. *Zprávy lesnického výzkumu*. 2016, vol. 61, no. 3, p. 223-229. ISSN 1805-9872.
- MÁRTONFI, P. *Systematika cievnatých rastlín*. 2nd. ed. Košice: Univerzita Pavla Jozefa Šafárika v Košiciach, 2006. 220 p. ISBN 80-7097-628-4.
- MIELKE, M., S.; LOBO, L., S.; DA COSTA, G., S.; SCHILLING, A., C.; DOS SANTOS, M., S. et al. Predictions of chlorophyll concentrations in the leaves of seedlings of two congeneric tropical trees from RGB digital image components. *Southern Forests: a Journal of Forest Science* [online]. 2021, vol. 83, no. 2, p. 177-184. [cit. 2024-02-28]. ISSN 2070-2620. Dostupné z: <https://doi.org/10.2989/20702620.2021.1928566>.
- MUSIL, I.; HAMERNÍK J.; LEUGNEROVÁ, G. *Lesnická dendrologie 1: jehličnaté dřeviny : přehled nahosemenných (i výtrusných) dřevin*. 2nd ed. Praha: Česká zemědělská univerzita, 2002. 177 p. ISBN 80-213-0992-X.
- PARASKEVOUDIS, K.; KARAYANNIS, P.; KOUMOULOS, E., P. Real-Time 3D Printing Remote Defect Detection (Stringing) with Computer Vision and Artificial Intelligence. *Processes* [online]. 2020, vol. 8, no. 11. [cit. 2024-02-28]. ISSN 2227-9717. Dostupné z: <https://doi.org/10.3390/pr8111464>.
- PAULE, L. *Genetika a šľachtenie lesných drevín*. Bratislava: Príroda, 1992. 304 p. ISBN 80-07-00409-2.
- POLANSKÝ, B. *Příspěvek k základům lesnické bioklimatologie a fenologie*. Brno: nákl. vlastním, 1937.
- POSPÍŠIL, J.; KOBLIHA, J. *Šlechtění lesních dřevin*. Brno: Vysoká škola zemědělská, 1988. 135 p.
- R CORE TEAM. *R: A language and environment for statistical computing*. R Foundation for Statistical Computing: Vienna, Austria. 2023. Dostupné z: <https://www.R-project.org>.

REDMON, J.; DIVVALA, S.; GIRSHICK, R. a FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection. *ArXiv* [online]. 2016. [cit. 2024-02-28]. Dostupné z: <https://doi.org/10.48550/arxiv.1506.02640>.

RENCZ, A., N.; RYERSON, R., A. (ed.). *Manual of Remote Sensing: Remote Sensing for the Earth Sciences*. 3rd ed. New York: Wiley, 1999. 728 p. ISBN 978-0-471-29405-4.

RINCENT, R.; CHARPENTIER, J., P.; FAIVRE-RAMPANT, P.; PAUX, E.; LE GOUIS, J. et al. Phenomic Selection Is a Low-Cost and High-Throughput Method Based on Indirect Predictions: Proof of Concept on Wheat and Poplar. *G3 Genes|Genomes|Genetics* [online]. 2018, vol. 8, no. 12, p. 3961-3972.[cit. 2024-02-26]. Dostupné z: <https://doi.org/10.1534/g3.118.200760>.

ROBOFLOW, INC. *Roboflow* [online]. [cit. 2024-03-28]. Dostupné z: <https://roboflow.com/>.

ROMAN, A.; URSU, T. Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks. In: OPREANU, C., H.; LĂZĂRESCU, V., A. (ed.). *Landscape archeology on the northern frontier of the Roman empire at Porolissum - an interdisciplinary research project* [online]. Cluj-Napoca: Mega Publishing House, 2016, p. 141-152. [cit. 2024-02-26]. ISBN 978-606-543-787-6. Dostupné z: <https://www.researchgate.net/publication/315797574>.

SANTINI, F.; KEFAUVER, S., C.; RESCO DE DIOS, V.; ARAUS, J., L.; VOLTAS, J. Using unmanned aerial vehicle-based multispectral, RGB and thermal imagery for phenotyping of forest genetic trials: A case study in *Pinus halepensis*. *Annals of Applied Biology* [online]. 2019, vol. 174, no. 2, p. 262-276. [cit. 2024-02-28]. ISSN 0003-4746. Dostupné z: <https://doi.org/10.1111/aab.12484>.

Seznam.cz, a.s. *mapy.cz* [online]. [2022] [2022-1-16] Dostupné z: <https://mapy.cz>.

SHAMEY, R. (ed.). *Encyclopedia of Color Science and Technology* [online]. 2nd. ed. Springer, 2023. [cit. 2024-02-26]. ISBN 978-3-030-89862-5. Dostupné z: <https://doi.org/10.1007/978-3-030-89862-5>.

SCHINDELIN, J.; ARGANDA-CARRERAS, I.; FRISE, E.; KAYNIG, V.; LONGAIR, M. et al. Fiji: an open-source platform for biological-image analysis. *Nature Methods* [online]. 2012, vol. 9, no. 7, p. 676-682. [cit. 2024-02-28]. ISSN 1548-7091. Dostupné z: <https://doi.org/10.1038/nmeth.2019>.

SIMS, D., A.; GAMON, J., A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment* [online]. 2002, vol. 81, no. 2-3, p. 337-354. [cit. 2024-03-14]. ISSN 00344257. Dostupné z: [https://doi.org/10.1016/S0034-4257\(02\)00010-X](https://doi.org/10.1016/S0034-4257(02)00010-X).

SKALSKI, P. *How to Train YOLOv7 Instance Segmentation on a Custom Dataset*. In: [blog.roboflow.com](https://blog.roboflow.com/train-yolov7-instance-segmentation-on-custom-data/) [online]. 2022. [cit. 2024-02-28]. Dostupné z: <https://blog.roboflow.com/train-yolov7-instance-segmentation-on-custom-data/>.

SKOOG, D., A.; HOLLER, F., J.; CROUCH, S., R. *Principles of Instrumental Analysis*. 7th ed. Boston: Cengage Learning, 2018. ISBN 978-1-305-57721-3.

SLÁVIK, M.; BAŽANT, V. *Dřevařská dendrologie I*. Praha: Česká zemědělská univerzita, 2016. 107 p. ISBN 978-80-213-2622-4.

SONNENTAG, O.; HUFKENS, K.; TESHARA-STERNE, C.; YOUNG, A., M.; FRIEDL, M. et al. Digital repeat photography for phenological research in forest ecosystems. *Agricultural and Forest Meteorology* [online]. 2012, vol. 152, p. 159-177. ISSN 01681923. [cit. 2024-03-14]. Dostupné z: <https://doi.org/10.1016/j.agrformet.2011.09.009>.

STEJSKAL, J.; ČEPL, J.; NEUWIRTHOVÁ, E.; AKINYEMI, O., O.; CHUCHLÍK, J. et al. Making the Genotypic Variation Visible: Hyperspectral Phenotyping in Scots Pine Seedlings. *Plant Phenomics* [online]. 2023, vol. 5. [cit. 2024-02-26]. Dostupné z: <https://doi.org/10.34133/plantphenomics.0111>.

SVOBODA, J.; ČERVENSKÝ, J.; DOHNAL, M.; DOHNANSKÝ, T.; FIŠER, K. et al. Koncepte zachování a reprodukce genových zdrojů lesních dřevin u Lesů České republiky, s. p., na období 2010–2019. 2010. Dostupné z: https://semenarskyzavod.cz/wp-content/uploads/Dokumenty/lcr_koncepce_lesni_dreviny_gen_zdroje.pdf.

TAIZ, L.; ZEIGER, E. *Plant Physiology*. 3rd ed. Sunderland: Sinauer Associates, 2002. ISBN 0878938230.

TAULAVUORI, E.; TAULAVUORI, K.; NIINIMAA, A.; LAINE, K. Effect of Ecotype and Latitude on Growth, Frost Hardiness, and Oxidative Stress of South to North Transplanted Scots Pine Seedlings. *International Journal of Forestry Research* [online].

2010, vol. 2010, p. 1-16. [cit. 2024-03-14]. ISSN 1687-9368. Dostupné z: <https://doi.org/10.1155/2010/162084>.

TERVEN, J.; CORDOVA-ESPARZA, D. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine learning and knowledge extraction* [online]. 2023, vol. 5, no. 4, p. 1680-1716. [cit. 2024-02-28]. ISSN 2504-4990. Dostupné z: <https://doi.org/10.48550/arXiv.2304.00501>.

TOMÁŠKOVÁ, I.; KUBÁSEK, J. *Fyziologie lesních dřevin I.: fyziologie, produkce a stresy rostlin*. Praha: Česká zemědělská univerzita v Praze, Fakulta lesnická a dřevařská, katedra genetiky a fyziologie lesních dřevin, 2016. 267 p. ISBN 978-80-213-2608-8.

ÚRADNÍČEK, L.; CHMELAR, J. *Dendrologie lesnická: 1. část Jehličnany*. Brno: Mendelova zemědělská a lesnická univerzita, 1995. ISBN 80-715-7162-8.

VAN ROSSUM, G.; DRAKE, F. L. *Python 3 Reference Manual*. Scotts Valley, CA: CreateSpace. (2009). ISBN 978-1-4414-1269-0

WALIA, M. *Semantic Segmentation vs. Instance Segmentation: Explained*. In: blog.roboflow.com [online]. 2022. [cit. 2024-02-28]. Dostupné z: <https://blog.roboflow.com/difference-semantic-segmentation-instance-segmentation/>.

WANG, C., Y.; BOCHKOVSKIY, A.; LIAO, H., Y., M. YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors. Online. In: *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2023, p. 7464-7475. [cit. 2024-02-28]. ISBN 979-8-3503-0129-8. Dostupné z: <https://doi.org/10.1109/CVPR52729.2023.00721>.

WHITE, T. L.; ADAMS, W. T.; NEALE, D. B. (eds.) *Forest genetics*. Wallingford: Cabi, 2007. 896 p. ISBN 978 0 85199 348 5.

ZHANG, H.; GE, Y.; XIE, X.; ATEFI, A.; WIJEWARDANE, N., K. et al. High throughput analysis of leaf chlorophyll content in sorghum using RGB, hyperspectral, and fluorescence imaging and sensor fusion. *Plant Methods* [online]. 2022, vol. 18, no. 60. [cit. 2024-02-26]. Dostupné z : <https://doi.org/10.1186/s13007-022-00892-0>.

ZICHA, O. borovice lesní. *BioLib* [online]. 2011 [cit. 2024-02-28]. Dostupné z: <https://www.biolib.cz/cz/taxon/id2312/>.

9. Seznam obrázků

Obrázek 1: Mapa přirozeného areálu borovice lesní ..	19
Obrázek 2: Šlechtitelský cyklus.....	23
Obrázek 3: Struktura chlorofylů a a b (A) a β -karotenu (B).....	29
Obrázek 4: Absorbanční křivky rostlinných pigmentů.....	30
Obrázek 5: Spektrální data ve formě datové kostky (datacube)	31
Obrázek 6: Elektromagnetická vlna a její charakteristiky	32
Obrázek 7: Křivka spektrální odrazivosti s uvedenými hlavními absorpčními a reflektančními vlastnostmi.....	34
Obrázek 8: Schéma spektrometru.....	35
Obrázek 9: Funkce standardního kolorimetrického pozorovatele CIE pro hodnoty RGB.	41
Obrázek 10: Model systému RGB s kartézskými souřadnicemi základních a sekundárních barev.....	43
Obrázek 11: Model systému HSV	45
Obrázek 12: Schématické vysvětlení IoU.....	48
Obrázek 13: Schématické zobrazení principu detekce objektů algoritmu YOLO.....	49
Obrázek 14: Rozdíl mezi rozpoznáváním obrazu, detekcí objektů, sémantickou segmentací a segmentací instancí objektů	50
Obrázek 15: Anotovaný semenáček borovice	51
Obrázek 16: Poloha vybraných semenných sadů na mapě České republiky	52
Obrázek 17: Schématická ukázka rozežrání obrázku s odsazením 400 pixelů dolů	57
Obrázek 18: Část fotografie před a po segmentaci upraveným algoritmem YOLOv7 a výsledek po odstranění pozadí.	58
Obrázek 19: Výstup po spojení jednotlivých vyřiznutých částí	59
Obrázek 20: Sjednocení jednotlivých výstupů do finálního obrázku	60
Obrázek 21: Schématické zobrazení identifikace a zjišťování průměrných RGB hodnot.	61
Obrázek 22: Průměrné barvy semenáčků v různých obdobích.....	65
Obrázek 23: Analýza hlavních komponent pro hodnoty HSV v různých obdobích.	66
Obrázek 24: Barevné kolo s hodnotami odstínu a sytosti dle populací a období	67
Obrázek 25: Analýza hlavních komponent pro hodnoty RGB v různých obdobích.	68

10. Seznam tabulek

Tabulka 1: Průměrné datum nástupu fenofáze podle nadmořské výšky	27
Tabulka 2: Všeobecné údaje o semenných sadech	53
Tabulka 3: Vybraná meteorologická data ze stanice Plzeň – Bolevec..	54
Tabulka 4: Hodnoty korelačního koeficientu pro jednotlivé parametry barevných systémů HSV a RGB.	69
Tabulka 5: Hodnoty koeficientu determinace (R^2) modelů PSLR pro parametry barevných systémů HSV a RGB a korelační koeficienty určující sílu vztahu mezi barvou získanou segmentací a barvou získanou predikcí pomocí PLSR modelu.....	69
Tabulka 6: Hodnoty Waldova testu s jeho p-hodnotou a LR testu s jeho p-hodnotou a heritabilitou pro parametry HSV v různých obdobích.....	70
Tabulka 7: Výsledky mnohonásobného porovnávání pro HSV a hodnota LSD použitá jako testová statistika.	71
Tabulka 8: Hodnoty Waldova testu s jeho p-hodnotou a LR testu s jeho p-hodnotou a heritabilitou pro parametry RGB v různých obdobích.	72
Tabulka 9: Výsledky mnohonásobného porovnávání pro RGB a hodnota LSD použitá jako testová statistika.	72

11. Seznam rovnic


Rovnice (1): Bilanční rovnice zářivého toku	33
Rovnice (2): Bilanční rovnice zářivého toku s využitím podílů	33
Rovnice (3): Vyjádření reflektance	33
Rovnice (4): Spektrální intenzita odraženého záření $Spec(\lambda)$	42
Rovnice (5): Intenzita červené barvy v rámci viditelného spektra	42
Rovnice (6): Intenzita zelené barvy v rámci viditelného spektra	42
Rovnice (7): Intenzita modré barvy v rámci viditelného spektra	42
Rovnice (8): Normalizace červeného kanálu RGB	42
Rovnice (9): Normalizace zeleného kanálu RGB	42
Rovnice (10): Normalizace modrého kanálu RGB	42
Rovnice (11): Výpočet HSV parametru odstínu ze systému RGB	44
Rovnice (12): Výpočet HSV parametru sytosti ze systému RGB	44
Rovnice (13): Výpočet HSV parametru jasu ze systému RGB	44
Rovnice (14): Výpočet parametru α pro výpočet HSV hodnot ze systému RGB	44
Rovnice (15): Výpočet parametru β pro výpočet HSV hodnot ze systému RGB	44
Rovnice (16): Výpočet parametru Δ pro výpočet HSV hodnot ze systému RGB	44
Rovnice (17): Pearsonův korelační koeficient	63

12. Přílohy

Příloha 1: Rozmístění populací během pěstování.....	95
Příloha 2: Pořadí měření sadbovačů a jednotlivých semenáčků.....	96
Příloha 3: Rozdíl ve výsledcích průměrů u různě rozložených dat.....	97
Příloha 4: Histogramy odstínu, sytosti a jasu v různých obdobích.....	98
Příloha 5: Histogramy hodnot R, G a B v různých obdobích.....	101
Příloha 6: Grafy importance vlnových délek v modelu PLSR.....	104

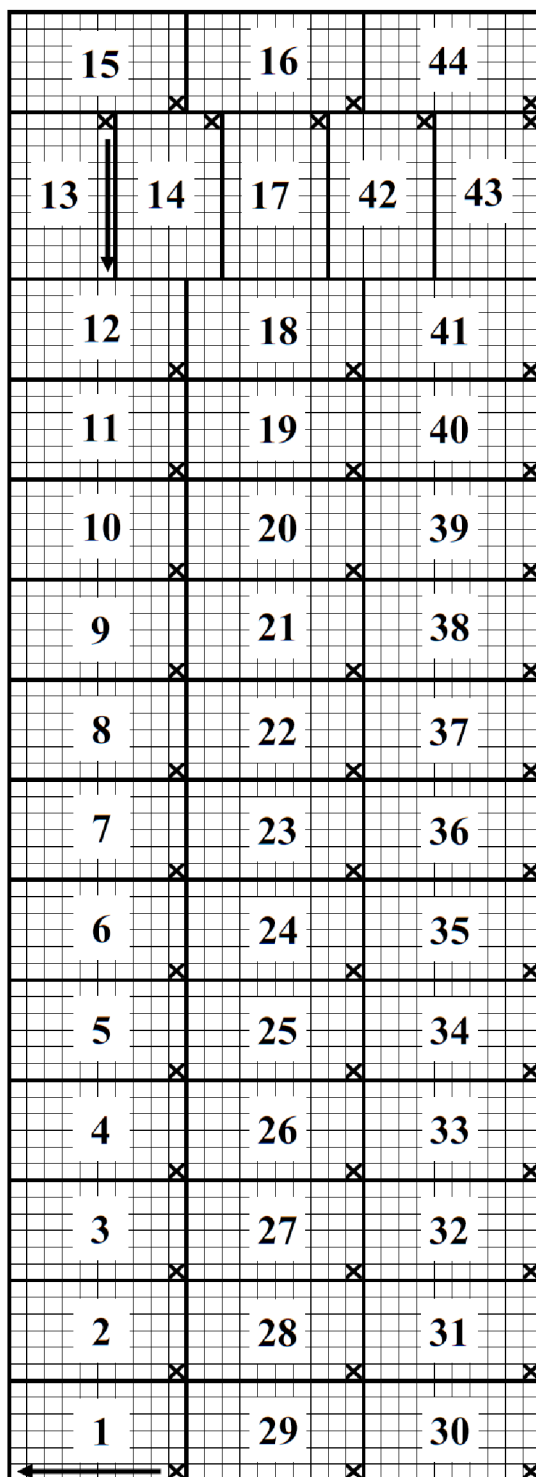
Příloha 1: Rozmístění populací během pěstování.

Tučné čáry vyznačují jednotlivé sadbovače. Barva sadbovačů je vztažena k jednotlivým populacím semenáčků pěstovaných v sadbovačích. Zelená barva odpovídá plaské populaci, okrová barva odpovídá třeboňské populaci a modrá barva vyznačuje děčínskou populaci.



Příloha 2: Pořadí měření sadbovačů a jednotlivých semenáčků.

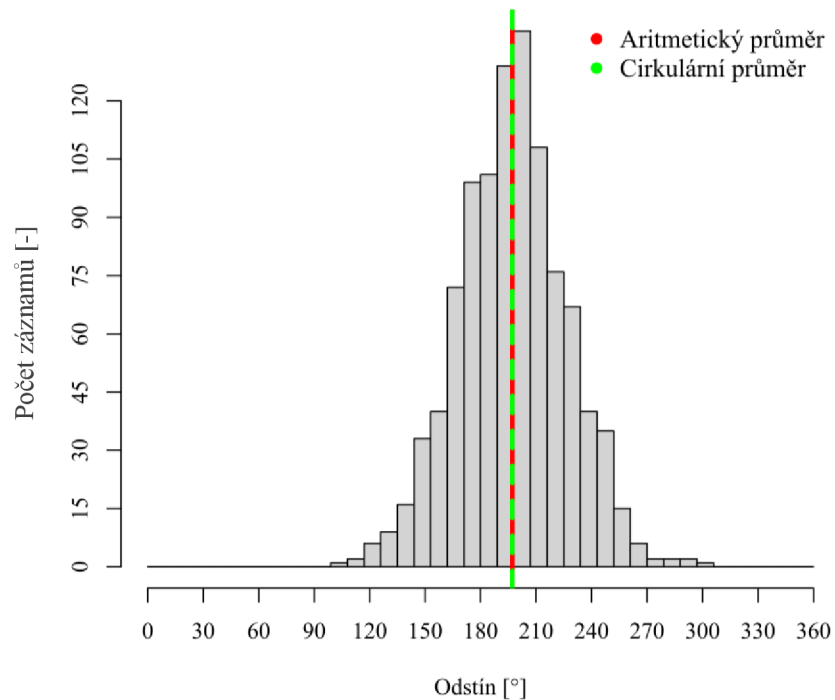
Tučné čáry vyznačují jednotlivé sadbovače. Tenké čáry vyznačují jednotlivé buňky se semenáčky v rámci sadbovačů. Číslo uprostřed udává pořadí, ve kterém byly sadbovače měřeny. Proškrtnutá buňka udává první semenáček měřený v rámci sadbovače. Šipky udávají směr, ve kterém měření pokračovalo. Po změření celého sloupce se začal měřit vedlejší sloupec.




Příloha 3: Rozdíl ve výsledcích průměrů u různě rozložených dat.

Grafy zobrazují rozdíl ve výsledcích při výpočtu aritmetického a cirkulárního průměru. Pokud data leží mezi hodnotami 0° a 360° , výsledky průměrů se shodují. Pokud přičteme nebo odečteme od každé hodnoty konstantu a rozdělení se posune přes hranici 0° nebo 360° , výsledné průměry budou odlišné.

Průměry pro data v intervalu 90° – 310°



Průměry pro data v intervalu 260° – 110°



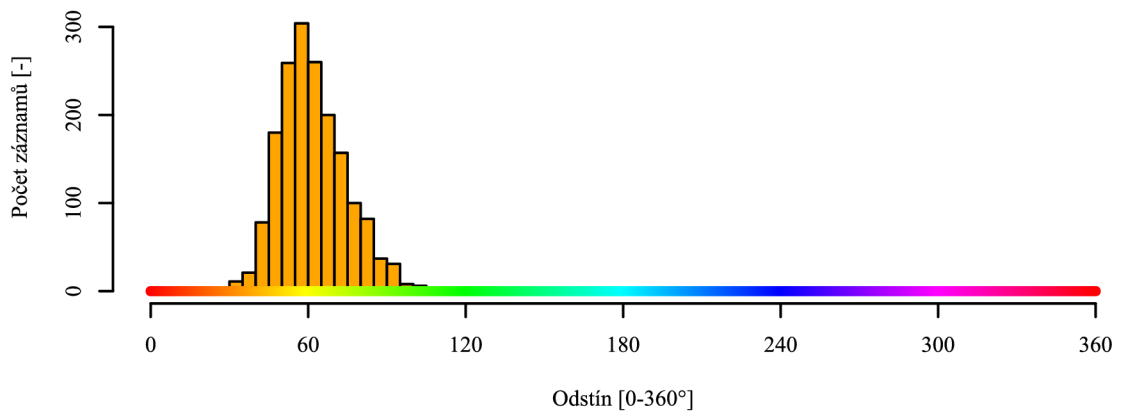
Příloha 4: Histogramy odstínu, sytosti a jasu v různých obdobích.

Sady grafů (A, B, C) zobrazují posun hodnot odstínu, sytosti a jasu v různých obdobích.

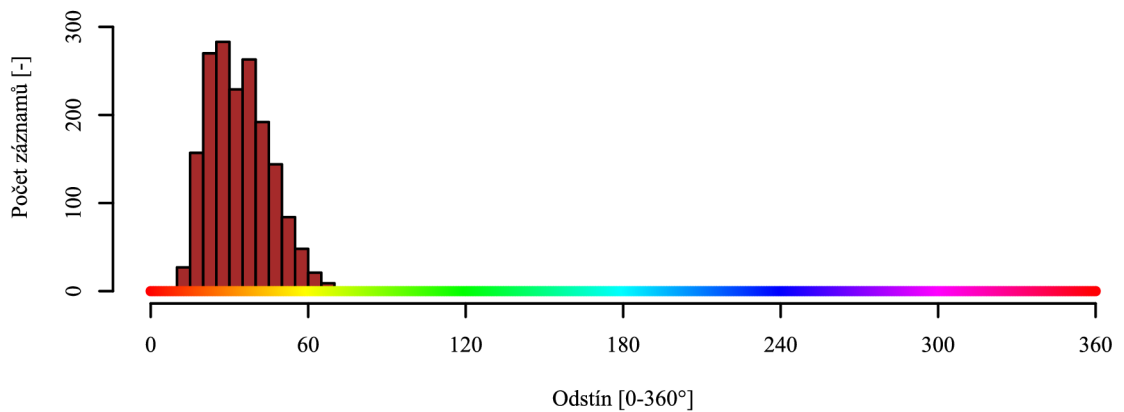
První sada histogramů (A) zobrazuje posun odstínu od žluto-zelené až k červeným odstínům.

A)


Září



Říjen




Leden




Druhá sada histogramů (B) zobrazuje posun sytosti v rámci 3 měřených období. Září a říjen vykazují poměrně shodné hodnoty sytosti, lednové sytosti jsou nižší.

B)



Třetí sady histogramů (C) ukazuje posun jasu v rámci měřených období. Hodnoty jasu jsou rozprostřeny v září a říjnu kolem hodnoty 0,5. V lednu se jas posouvá k vyšším hodnotám.

C)




Příloha 5: Histogramy hodnot R, G a B v různých obdobích.

Sady grafů (A, B, C) zobrazují posun hodnot R, G a B v různých obdobích.


První sada histogramů (A) zobrazuje posun červeného kanálu. Červený kanál je v září a říjnu poměrně srovnatelný, v lednu jeho hodnota stoupá.

A)


Červená složka - září




Červená složka - říjen



Červená složka - leden




Druhá sada histogramů (B) zobrazuje posun zeleného kanálu. Hodnoty zeleného kanálu jsou podobné u zářijových a lednových dat. U říjnových dat hodnoty klesají.



Třetí sada histogramů (C) zobrazuje posun modrého kanálu. Hodnoty modrého kanálu viditelně rostou u lednových dat.

C)




Příloha 6: Grafy importance vlnových délek v modelu PLSR

Grafy zobrazují průměrnou reflektanční křivku v rozmezí 350–750 nm a importanci dané vlnové délky v 1. komponentě modelu PLSR. VIP skóre je měřítkem důležitosti proměnné v modelu PLSR. Shrnuje příspěvek proměnné k modelu. Obecně uznávaná hranice, která udává statistickou důležitost dané proměnné je 1,0. Tato hranice je v grafech vynesena přerušovanou čarou. Vlnové délky, jejichž VIP skóre je nad touto hranicí jsou pro model a 1. komponentu statisticky významné.


U modelu pro odstín se nejdůležitější vlnové délky použité pro predikci odstínu nacházejí v oblasti 580–680 nm a v oblasti red-edge. Od vlnové délky 730 importance opět stoupá.

Importance vlnových délek 1. komponenty v modelu PLSR pro odstín v systému HSV




Model použitý k predikci sytosti využívá podobné vlnové délky jako model pro odstín, pouze v oblasti 670–690 nejsou vlnové délky tak významné.

Importance vlnových délek 1. komponenty v modelu PLSR pro sytost v systému HSV



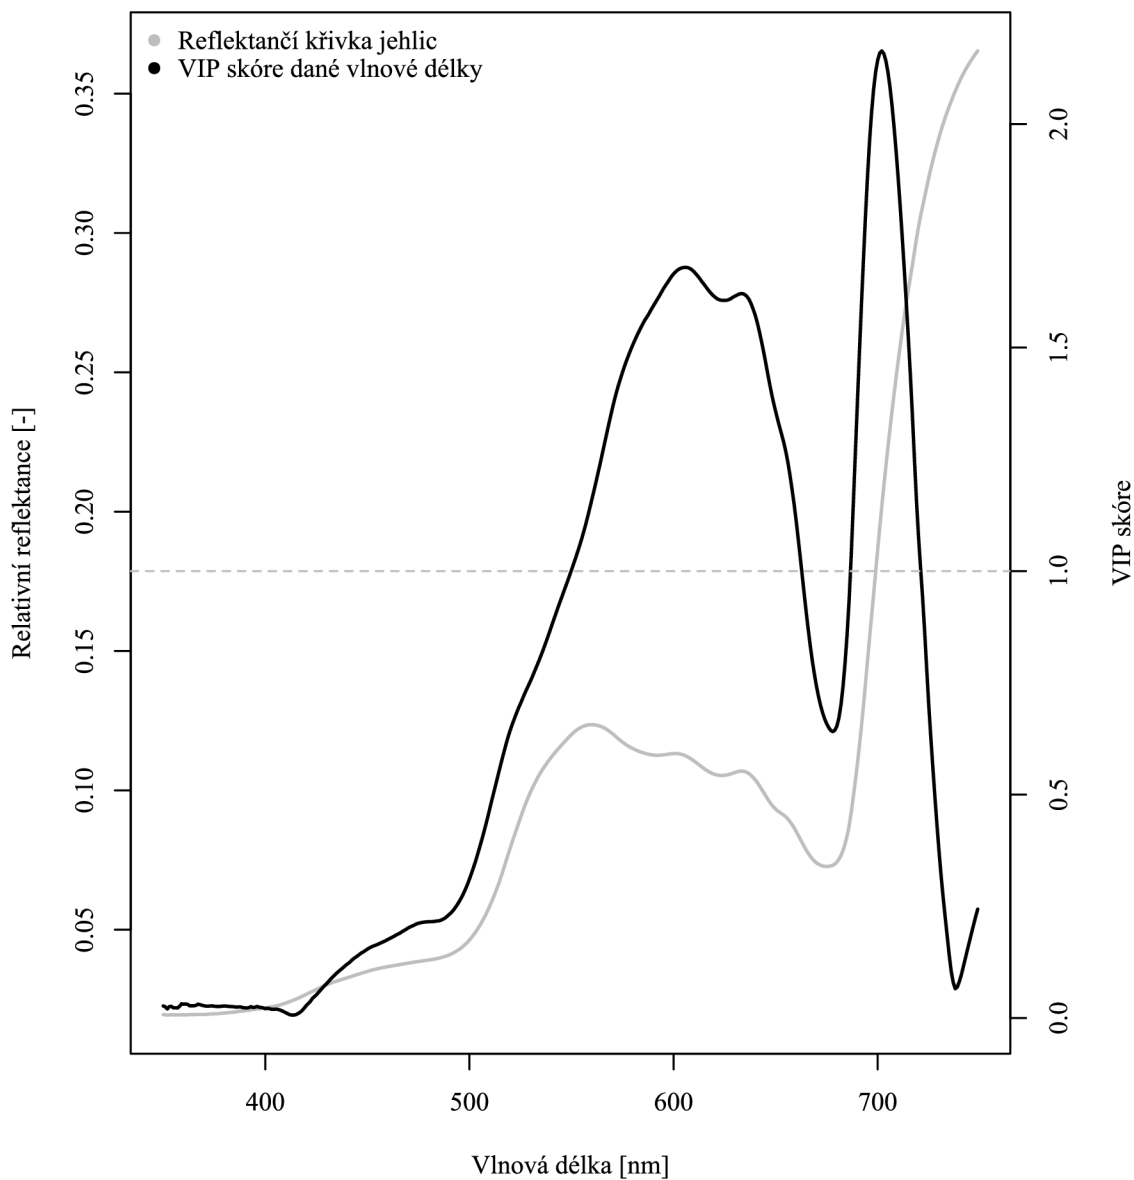
Importance vlnových délek v modelu pro predikci jasu jsou posunuté směrem k nižším vlnovým délkám asi o 50 nm. Nicméně v oblasti red-edge jsou importance podobné jako u předcházejících modelů pro odstín a sytost.

Importance vlnových délek 1. komponenty v modelu PLSR pro jas v systému HSV




Model pro predikci červeného kanálu RGB z hyperspektrálních dat má největší importance v červeném pásmu VIS a v oblasti red edge. V oblasti pod 530 nm nejsou vlnové délky pro model příliš přínosné.

Importance vlnových délek 1. komponenty v modelu PLSR pro červenou složku v systému RGB



U modelu pro zelený kanál systému RGB se importance přesouvají nad zelené pásmo VIS. Zároveň na začátku oblasti NIR kopírují importance reflektanční křivku a není zde vidět taková důležitost REIP jako u modelu pro červený kanál nebo u modelů pro HSV.

Importance vlnových délek 1. komponenty v modelu PLSR pro zelenou složku v systému RGB



U modelu pro predikci modrého kanálu RGB se posouvají nejdůležitější vlnové délky asi o 10 nm k nižším číslům. Zároveň roste významnost modrého pásma, přestože zdaleka nepřekračuje hranici pro významnost dle VIP skóre. V NIR je opět reflektanční křivka kopírována importancí, stejně jako u zeleného kanálu.

Importance vlnových délek 1. komponenty v modelu PLSR pro modrou složku v systému RGB

